

## Классификация интенсивности цветения водорослей на основе методов машинного обучения и гиперспектральных данных БПЛА

И.А. Новиков<sup>1</sup>, А.Р. Макаров<sup>2,3</sup>, В.В. Подлипов<sup>2,3</sup>, В.И. Платонов<sup>3</sup>, Д.Д. Рыськова<sup>3</sup>, О.В. Калашникова<sup>3</sup>, Р.М. Хабибуллин<sup>2,3</sup>, Р.В. Скиданов<sup>2,3</sup>, С.В. Илларионова<sup>1</sup>, Ю.В. Выборнова<sup>3</sup>, А.В. Никоноров<sup>2,3</sup>, Д.Г. Шадрин<sup>1</sup>, Т.В. Подладчикова<sup>1</sup>

<sup>1</sup> Сколковский институт науки и технологий, 121205, Россия,  
г. Москва, Сколково, Большой бульвар, д. 30, стр. 1;

<sup>2</sup> Институт систем обработки изображений, НИЦ «Курчатовский институт»,  
443001, Россия, г. Самара, ул. Молодогвардейская, д. 151;

<sup>3</sup> Самарский национальный исследовательский университет имени академика С.П. Королёва,  
443086, Россия, г. Самара, Московское шоссе, д. 34

### Аннотация

В работе представлен подход к анализу гиперспектральных изображений высокого пространственного разрешения в прикладной задаче анализа состояния речных вод. Данный метод позволяет обнаружить цветение или загрязнение воды посторонними веществами. Гиперспектральные изображения высокого разрешения были получены с помощью гиперспектрометра, установленного на малом беспилотном летательном аппарате. Продемонстрирована разница между спектрами участков реки с разной интенсивностью цветения водорослей. Были взяты пробы речной воды, проведен химический анализ, который подтвердил различное содержание магния и кальция во всех пробах, соответствующее интенсивности цветения водорослей в воде. Для классификации акваторий с различной интенсивностью цветения водорослей было рассмотрено несколько алгоритмов классификации на основе машинного обучения и вегетационных индексов. Показана эффективность использования алгоритмов машинного обучения по сравнению с вегетационными индексами. Рассмотрено и проведено сравнение нескольких подходов понижения размерности гиперспектральных данных на основании селекции спектральных каналов для повышения производительности наиболее эффективных алгоритмов классификации.

**Ключевые слова:** гиперспектрометр, спектральный анализ, гиперспектральные изображения, индексные изображения, машинное обучение.

**Цитирование:** Новиков, И.А. Классификация интенсивности цветения водорослей на основе методов машинного обучения и гиперспектральных данных БПЛА / И.А. Новиков, А.Р. Макаров, В.В. Подлипов, В.И. Платонов, Д.Д. Рыськова, О.В. Калашникова, Р.М. Хабибуллин, Р.В. Скиданов, С.В. Илларионова, Ю.В. Выборнова, А.В. Никоноров, Д.Г. Шадрин, Т.В. Подладчикова // Компьютерная оптика. – 2025. – Т. 49, № 6. – С. 972-985. – DOI: 10.18287/2412-6179-CO-1539.

**Citation:** Novikov IA, Makarov AR, Podlipnov VV, Platonov VI, Ryskova DD, Kalashnikova OV, Khabibullin RM, Skidanov RV, Illarionova SV, Vybornova YV, Nikonorov AV, Shadrin DG, Podladchikova TV. Algae bloom intensity classification using machine learning methods and UAV hyperspectral data. Computer Optics 2025; 49(6): 972-985. DOI: 10.18287/2412-6179-CO-1539.

### Введение

Контроль загрязнения прибрежных вод является актуальной проблемой в промышленных регионах [1]. Традиционный мониторинг качества воды использует ручные методы отбора проб и тестирования. Они неэффективны, требуют больших затрат ресурсов, не позволяют точно описать качество воды на всей акватории и могут иметь временные разрывы [2]. Поэтому необходима разработка более единообразных и надежных методов мониторинга состояния воды, способных отслеживать загрязненность водоема на больших временных и пространственных масштабах и не подверженных влиянию разнообразных

условий окружающей среды. За последние десятилетия технология дистанционного зондирования Земли (ДЗЗ) стала ценным источником данных, предоставляющим пространственно явную и объективную информацию о состоянии окружающей среды [3] и, в частности, о параметрах качества воды, взвешенных осадков (мутности), хлорофилла и температуры [4–6].

Выбор технологии дистанционного зондирования Земли с использованием спутников и беспилотных летательных аппаратов (БПЛА) определяется в первую очередь областью применения и имеющимся бюджетом. Спутниковое ДЗЗ подходит для мониторинга больших площадей, однако требует и больших денежных затрат в случае использования данных вы-

сокого пространственного разрешения [7]. В это же время БПЛА предоставляет большую гибкость в использовании, меньшую стоимость и большее пространственное разрешение, поэтому лучше подходит для исследования малых рек [8]. Получить информацию о спектральной составляющей воды можно с помощью специализированных приборов, например, гиперспектрометра, который позволяет сопоставить полученные спектры с составом минеральной воды [9, 10]. Это позволит использовать данные зондирования Земли для прогнозирования изменений окружающей среды и интегрировать результаты в системы мониторинга [11].

Водоросли, являющиеся ключевым индикатором качества воды, играют важную роль в понимании состояния экосистемы [12]. Например, в статье [13] рассмотрено вредоносное влияние цветения водорослей на экосистему и здоровье человека. С помощью гиперспектрального дистанционного зондирования можно повысить точность отслеживания водорослей. Благодаря способности анализировать в различных узких спектральных диапазонах, гиперспектральная технология обладает потенциалом для лучшего различения и оценки биофизических атрибутов [14].

Существуют различные подходы для мониторинга водорослей с помощью ДЗЗ. Они основываются на методах построения вегетационных индексов, таких как NDVI (Normalized Difference Vegetation Index – Нормализованный разностный вегетационный индекс) [15], и методах машинного [16] и глубокого обучения [17, 18], которые являются мощными инструментами отслеживания состояния воды при различных условиях окружающей среды [19]. В том случае, если цветение водорослей рассматривается как основной параметр загрязненности водоема, ввиду проблематичности дифференциации видов водорослей между собой, для контроля изменения биомассы водорослей используется концентрация Chl-a (Chlorophyll a – Хлорофилл а) [20–23]. В работе [24] рассмотрена модель глубокого обучения, позволяющая идентифицировать области цветения водорослей на основании дистанционного зондирования озера Чаоху. В статьях [25, 26] рассматривается классификация водорослей на основании гиперспектральных данных без использования Chl-a в качестве исследуемого параметра. Однако в данных статьях в качестве алгоритмов классификации были рассмотрены математические алгоритмы, такие как метод максимального правдоподобия и SAM (Spectral Angle Mapper – Классификация по спектральному углу).

Мы предлагаем использовать распределение интенсивности цветения водорослей в качестве одного из признаков для определения химического состава воды. В статье [27] описывается подход по отслеживанию концентрации тяжелых металлов (Cu и Fe) в озере Далянь, Шанхай, на основании гиперспектральных данных и показателей качества воды (кон-

центрации Chl-a, TOC (Total Organic Carbon – Общий органический углерод), DO (Dissolved Oxygen – Растворенный кислород) и др.). В ситуации, когда отсутствуют подобные показатели, использование распределения интенсивности цветения водорослей должно упростить решение подобной задачи.

Целью данной работы является создание метода для осуществления классификации интенсивности цветения водорослей методами машинного обучения на основе полученных с БПЛА гиперспектральных данных в условиях их ограниченности. Была осуществлена предобработка гиперспектральных данных методом SNV (Standard Normal Variate – Стандартная нормированная вариация). Для решения задачи классификации было рассмотрено несколько подходов: на основе построения вегетационных индексов (NDVI, TCARI (Transformed Chlorophyll Absorption Reflectance Index – Трансформированный относительный индекс поглощения в хлорофилле), OSAVI (Optimized Soil Adjusted Vegetation Index – Вегетационный индекс, учитывающий влияние почвы при несомкнутом растительном покрове), NDWI (Normalized Difference Water Index – Нормализованный разностный водный индекс), ChlRI (Chlorophyll Reflection Index – Отражательный индекс хлорофилла) (подробнее в подпараграфе 2.1) и использования алгоритмов классификации SAM, kNN (k-nearest neighbors – k-ближайших соседей), SVM (Support Vector Machine – Метод опорных векторов), M1DCNN, NM3DCNN (подробнее в подпараграфе 2.2). Для повышения результатов классификации осуществлена селекция спектральных каналов. Для этого было рассмотрено несколько подходов на основании алгоритмов понижения размерности данных, таких как PCA (Principal Component Analysis – Метод главных компонент), SNPA (Successive Nonnegative Projection Algorithm – Метод последовательных неотрицательных проекций), SAA (Simulated Annealing Algorithm – Метод имитационного отжига) (подробнее в подпараграфе 2.3).

Резюмируя, вклад данной работы следующий:

1. Проведен сбор и химический анализ данных, полученных для реки Чапаевка, Самарская область.
2. Реализованы различные подходы классификации интенсивности цветения водорослей: на основании построения вегетационных индексов и аналитических методов. Проведено сравнение между ними.
3. Реализовано несколько подходов селекции спектральных каналов на основе методов понижения размерности данных, и выявлены наиболее эффективные из них.

## **1. Сбор и обработка данных**

### ***1.1. Получение гиперспектральных изображений***

В начале сентября 2023 года был выполнен сбор гиперспектральных данных речных вод на реке Чапаевка в областях с различной степенью цветения водо-

рослей. Для этого было выделено два дня. 01.09.23 были проведены съемки в точках «Причал» и «Горки» (рис. 1а, б), в то время как 08.09.23 прошли съемки в точках «Маяк» и «Малое Томылово» (рис. 2а, б). Названия выбранных точек съемки реки соответствовали ближайшим населенным пунктам.

В первый день съемок были ясные погодные условия, что определило более высокую интенсивность освещения, в то время как во второй день съемок наблюдалась облачность, снижающая уровень освещения. Из-за различных погодных условий отличались условия съемки ГСИ (первый день солнечный, второй облачный), поэтому проводилось сравнение точек «Причал» и «Горки», «Маяк» и «Малое Томылово» между собой соответственно. Сравнимые пары локаций были сформированы на основании схожести погодных условий. Далее в работе проводилось исследование совмещенных ГСИ по условиям съемки (высокий уровень освещенности/низкий уровень освещенности).

В качестве исследуемой области при помощи гиперспектрометра также была рассмотрена центральная часть реки. Это исключает влияние дна на отраженный спектр воды, и будет снята та область реки, где брались пробы для химического анализа.



Рис. 1. Река Чапаевка. Локации: а) «Горки», б) «Причал»



Рис. 2. Река Чапаевка. Локации: а) «Маяк», б) «Малое Томылово»

Съемка проводилась с помощью щелевого гиперспектрометра OF2023-03, построенного по схеме Оффнера [9, 10]. Параметры съемки указаны в табл. 1. В результате съемки с малого БПЛА были получены ГСИ, сформированные из видеоряда спектров. Пример спектра из видео представлен на рис. 3. Видео соответствует данным телеметрии. После сборки ГСИ был сформирован RGB-синтез мест съемки. RGB-синтез представлен на рис. 4.



Рис. 3. Видеопоследовательность спектров, снятых на БПЛА



Рис. 4. Пример изображения, полученного методом RGB-синтеза из ГСИ в точках «Горки» и «Причал»

Табл. 1. Параметры съемки

Спектральный диапазон, нм	400 – 1000
Количество каналов	250
Разрешение матрицы, пкс	1020
Пространственное разрешение, м/пкс	0.01
Высота полета, м	30
Угол обзора	20°

### 1.2. Прототип гиперспектрометра на основе спектральных линз

В работе также использовано развитие концепции мультиапертурного полнокадрового гиперспектрометра на основе матрицы линз и узкополосных спектральных фильтров в плоскости матрицы регистрации [28]. Однако с точки зрения практической реализации такой гиперспектрометр достаточно сложен в изготовлении из-за технологии производства сегментированного узкополосного фильтра. Спектральная селективность гармонических линз в сочетании со стандартными фильтрами Байера для цветной матрицы позволяет создать намного более простой в изготовлении гиперспектрометр на основе матрицы гармонических линз.

Согласно [29] для гармонической линзы, рассчитанной для работы с длиной волны  $\lambda_0$ , возникает набор длин волн (гармоник), на которых эта линза также строит четкое изображений. Эти длины волн определяются по формуле

$$\lambda_k = \frac{m\lambda_0}{k},$$

где  $m$  – коэффициент, показывающий, во сколько раз высота микрорельефа гармонической линзы больше, чем высота микрорельефа дифракционной линзы на длину волны  $\lambda_0$ . Коэффициент  $m$  можно вычислить по формуле

$$m = \frac{h \cdot (n - 1)}{\lambda_0},$$

где  $h$  – высота микрорельефа,  $n$  – показатель преломления. Для линзы с высотой микрорельефа 6 мкм и  $\lambda_0 = 550$  нм  $m = 5$ , согласно формуле у этой линзы есть

еще две гармоники, которые попадают в видимый диапазон,  $\lambda_4=687$  нм,  $\lambda_6=458$  нм. Таким образом, естественным путем получается три спектральных канала, один из них регистрируется синими пикселями, один – зелеными и один – красными. Для получения большего количества каналов нужно использовать мультиапертурную систему, в которой гармонические линзы имеют разную высоту микрорельефа. С уменьшением высоты микрорельефа будут уменьшаться длины волн всех трех гармоник, и мы получим возможность с переменным интервалом покрыть видимую часть спектра. Для расчета и последующего изготовления была выбрана матрица размером  $4 \times 4$ . Высоты микрорельефа линз необходимо менять с постоянным шагом от 6 мкм до 5,25 мкм. Для сенсора Sony IMX 415 получилось 48 спектральных каналов, в основном расположенных почти равномерно. Однако есть два разрыва: между красными и зелеными гармониками 606 нм и 554 нм и между зелеными и синими гармониками 485 нм и 462 нм. Эти разрывы довольно критичны для большого количества практических задач. Размеры этих разрывов можно уменьшить за счет использования вместо части гармонических линз спектральных дифракционных линз, у которых положения красных и зеленых гармоник сдвигаются так, чтобы заполнить образующиеся разрывы. Дифракционный микрорельеф спектральных дифракционных линз содержит более высокочастотные элементы, чем микрорельеф дифракционных гармонических линз, поэтому было принято решение заменить в матрице  $4 \times 4$  четыре внутренних линзы на спектральные.

Для обеспечения точности формирования микрорельефа гармонические линзы для мультиапертурной системы формируются на одной подложке. На рис. 5 представлен внешний вид четырехлинзовой системы. Размер всей области записи –  $6,5 \times 6,5$  мм, диаметр апертуры линз – 2 мм.

Для эксперимента был частично модифицирован фотоаппарат Sony Alpha NEX-3 (рис. 6).

На рис. 7 представлены результаты эксперимента, в котором был снят светодиод SAWS0661A с известным спектральным распределением.

Для верификации результатов спектр диода SAWS0661A был измерен на высокоточном спектрометре. На рис. 8 представлены результаты измерения.

По критерию среднеквадратичного отклонения отличие спектра, полученного в эксперименте, от эталонного спектра составляет 0,23. Однако, если не учитывать отрезок от 650 нм до 700 нм, где присутствуют максимальные отклонения, связанные с особенностями чувствительности цветных матриц, среднеквадратичное отклонение составляет всего 0,087 (PSNR 21,2 дБ), что является вполне приемлемым результатом для гиперспектрометра. Сопоставление съемки прибрежной зоны разработанным гиперспектрометром на основе спектральных линз со съемкой референсным гиперспектрометром на основе моди-

фицированной схемы Оффнера с дифракционным диспергирующим элементом показало среднюю оценку PSNR в 25,3 дБ.

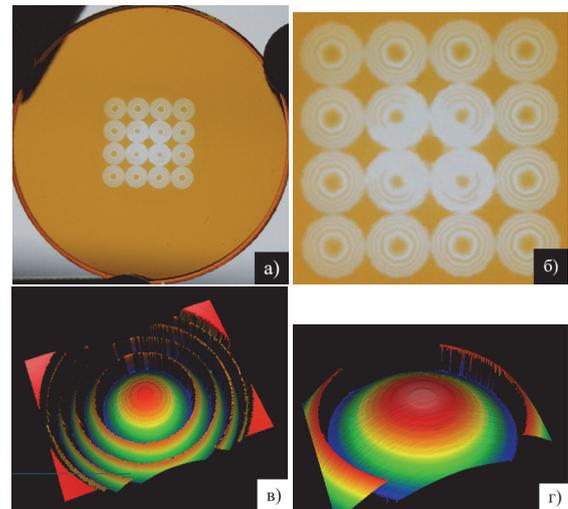


Рис. 5. Внешний вид всего элемента на подложке диаметром 25 мм (а), увеличенное изображение матрицы линз (б), трехмерная реконструкция рельефа одной из спектральных дифракционных линз (в), реконструкция центральной части микрорельефа гармонической линзы (г)

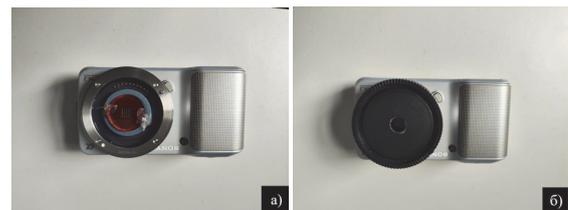


Рис. 6. Внешний вид модифицированного фотоаппарата с открытым ДООЭ (а) и с внешней диафрагмой (б)

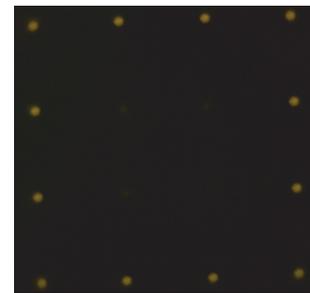


Рис. 7. Экспериментально полученные изображения светящегося диода SAWS0661A

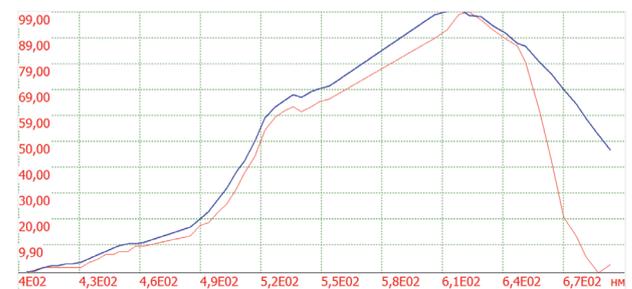


Рис. 8. Спектр светимости диода SAWS0661A – спектр с высокоточного спектрометра, построенный по точкам, соответствующим гармоникам матрицы линз, красный – спектр, полученный на экспериментальном гиперспектрометре

1.3. Анализ статистических данных

В рамках исследования проводился анализ воды методом оптико-эмиссионной спектроскопии при помощи спектрометра «PQ 9000» (Analytik Jena GmbH+Co. KG) [28-30] на наличие следующих микроэлементов: Ca, Cr, Ni, Cu, As, Cd, Fe, Mg. В значимых концентрациях в исследуемых образцах находились Ca и Mg, результаты определения которых представлены в табл. 2.

В общей сложности анализ химического состава воды показал разнообразие по микроэлементам в точках отбора проб, указанных в табл. 2. Из представленных данных видно, что концентрация микроэле-

ментов убывает по мере приближения к впадению исследуемой реки в реку Сухая Самарка. Данные результаты подтверждаются визуальной оценкой концентрации водорослей на разных участках реки (рис. 9). При этом концентрации Ca и Mg уменьшились в 1,3 и 1,4 раза соответственно. Из чего можно сделать вывод о том, что антропогенное воздействие на водоем максимально на начальной точке отбора («Причал»). После установления зависимости между изменением интенсивности цветения водорослей и количеством микроэлементов Mg и Ca в воде возможно выполнить сравнительный анализ речных участков на основе их спектров.

Табл. 2. Химический анализ воды

Номер пробы	Концентрация, мг/мл			
	Причал	Малое Томылово	Горки	Маяк
Ca	83,88	68,36	66,49	63,43
Mg	30,38	24,18	23,44	21,77



Рис. 9. Изображения участков реки Чапаевка. Локации: а) «Причал», б) «Малое Томылово», в) «Горки», з) «Маяк»

Для корректного сопоставления данных, полученных с помощью гиперспектрометра, для проведения спектрального анализа необходимо подтвердить, что условия освещенности при проведении съемки различных областей реки одинаковые. Для подтверждения факта схожести условий освещенности у сравниваемых ГСИ были выбраны участки с желтой травой. Данные участки были выбраны из-за отсутствия возможности размещения калибровочного инструмента «колорчекер» на месте съемки. Средние значения и дисперсии спектров выбранных участков представлены на рис. 10 и 11. Для проверки сходства спектров использовалась t-статистика с уровнем значимости 0,05. При сравнении двух спектров желтой травы на ГСИ «Горки» и ГСИ «Причал» значение p\_value составило 0,113, а на ГСИ «Маяк» и ГСИ «Малое Томылово» – 0,092. Это означает, что спектры желтой травы схожи у ГСИ «Горки» и ГСИ «Причал», ГСИ «Маяк» и ГСИ «Малое Томылово», что подтверждает равные условия освещения.

Было проведено сравнение средних спектров участков рек на ГСИ в локациях «Горки» и «Причал», «Маяк» и «Малое Томылово». Спектры выбранных участков рек представлены на рис. 12 и 13. Для проверки сходства спектров также использовалась t-статистика с уровнем значимости 0,05. При сравнении двух спектров акваторий на ГСИ «Горки» и ГСИ «Причал» значение p\_value составило 2,37e-17. При сравнении двух спектров акваторий ГСИ «Маяк» и ГСИ «Малое Томылово» значение p\_value составило 0,0018. При сравнении средних спектров речной воды р\_значения очень малы по сравнению с установленным уровнем значимости. Разница в спектрах акваторий ГСИ «Горки» и ГСИ «Причал», ГСИ «Маяк» и ГСИ «Малое Томылово» статистически значима.

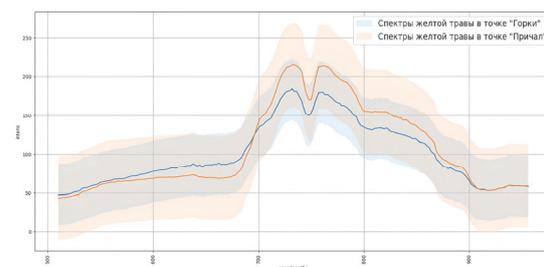


Рис. 10. Спектры отражения желтой травы в «Горках» и «Причале» при солнечном освещении

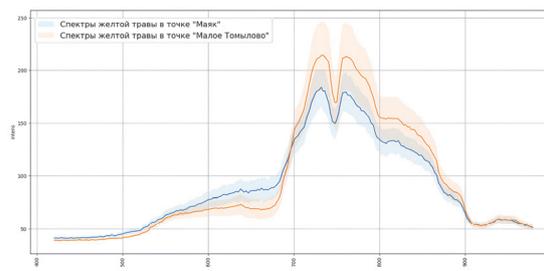


Рис. 11. Спектры отражения желтой травы на «Маяке» и «Малом Томылово» при солнечном освещении

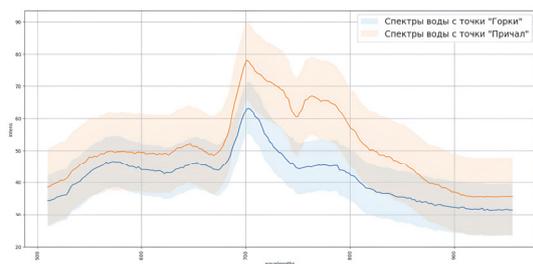


Рис. 12. Спектры отражения воды в «Горках» и «Причале» при солнечном освещении

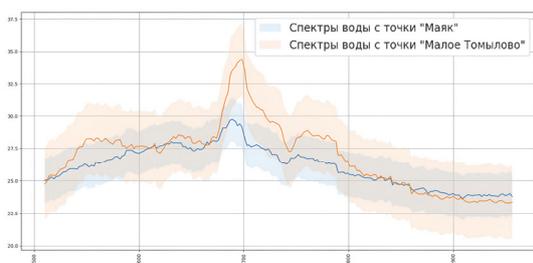


Рис. 13. Спектры отражения воды в «Маяке» и «Малом Томылово» при солнечном освещении

## 2. Аналитические методы и критерии оценивания

### 2.1. Вегетационные индексы и предобработка данных

Для определения наличия растительности существуют специализированные индексы, такие как NDVI [29 – 31], OSAVI [30 – 32]. Для количественной оценки хлорофилла и его потенциальной способности абсорбировать солнечный свет используются индексы TCARI [30 – 32] и chlRI [30 – 32]. Индекс NDWI [31 – 33] может быть использован для оценки содержания влаги в растительном покрове и измерения степени покрытия поверхностными водами.

$$NDVI = \frac{\rho_{800} - \rho_{670}}{\rho_{800} + \rho_{670}},$$

$$NDWI = \frac{\rho_{560} - \rho_{835}}{\rho_{560} + \rho_{835}},$$

$$OSAVI = \frac{(1 + 0,16)(\rho_{800} - \rho_{670})}{\rho_{800} + \rho_{670} + 0,16},$$

$$TCARI = 3\left[(\rho_{700} - \rho_{670}) - \frac{0,2\rho_{700}(\rho_{700} - \rho_{550})}{\rho_{670}}\right],$$

$$chlRI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2\rho_{445}},$$

где  $\rho_n$  означает коэффициент отражения исследуемого объекта на длине волны  $n$  нм.

Данные индексы могут быть использованы для определения интенсивности цветения водорослей в интересующих нас областях водоема.

В качестве метода предобработки гиперспектральных данных была использована стандартная нормированная вариация SNV. Метод предназначен для устранения мультипликативных помех, возникающих, например, при рассеянии излучения разных длин волн на частицах материала отличающегося

размера [32–34]. Для этого спектральные каналы каждого из пикселей  $i$  преобразуются за счет центрирования относительно их среднего значения  $X_i$  и деления на собственное среднее квадратичное отклонение  $\sigma_i$  [33–35]:  $X_i^{SNV} = (X_i - X_i) / \sigma_i$ .

### 2.2. Алгоритмы классификации цветения водорослей

В данной работе было проведено сравнение метода  $k$ -ближайших соседей kNN (как базового алгоритма), спектральной глубокой сверточной нейронной сети 1D-CNN [34–36], нормализованной пространственно-спектральной сверточной сети N3DCNN [35–37], классификации по спектральному углу SAM [36–38] и метода опорных векторов SVM [37–39]. На рис. 14 и 15 показано разделение исследуемых участков водоемов на обучающую и тестовую выборки. Два эксперимента между собой независимы, и в каждом эксперименте классы должны начинаться с 0 (игнорируемый класс при обучении и тестировании) и заканчиваться последним индексом (в нашем случае это «2»), то есть в каждом эксперименте присутствуют классы 0, 1 и 2. Локации «Маяк» и «Малое Томылово» обладают схожими концентрациями Ca и Mg, а значит, и схожей интенсивностью цветения водорослей. Низкая разделимость интенсивности цветения может привести к падению качества классификации, однако таким образом могут быть выявлены наиболее точные подходы для решения поставленной задачи. Слои ГСИ показаны на рис. 16 и 17. Для нивелирования переобучения моделей обучающая и тестовая выборки были составлены в соотношении 1:9 относительно друг друга. Размеры обучающих и тестовых выборок представлены в табл. 3.



Рис. 14. Разметка точек GPS-съемки «Горки» и «Причал»

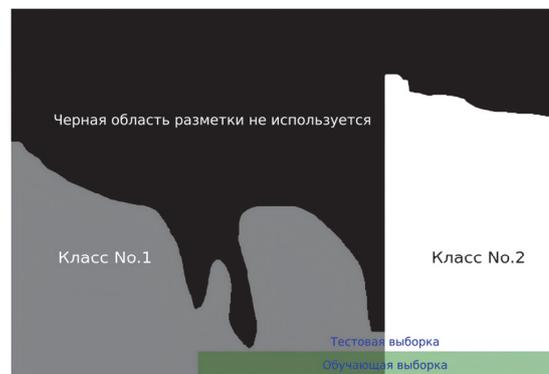


Рис. 15. Разметка точек GPS-съемки «Маяк» и «Малое Томылово»

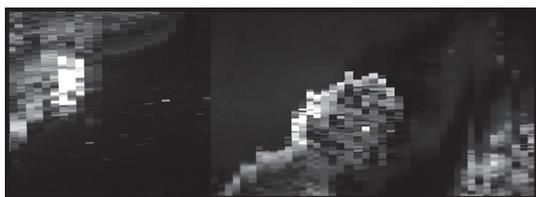


Рис. 16. Спектральный канал ГСИ 665 нм для локаций «Горки» и «Причал»

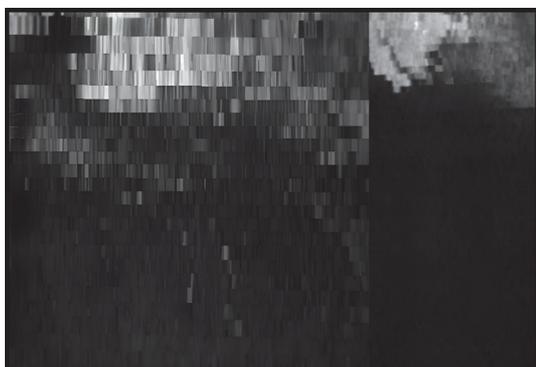


Рис. 17. Спектральный канал ГСИ 665 нм для локаций «Маяк» и «Малое Томылово»

Метод  $k$ -ближайших соседей – это метод машинного обучения, используемый для классификации и

регрессии. В контексте классификации для нового объекта, подлежащего классификации, вычисляется расстояние до каждого из объектов обучающей выборки, и из них выбираются  $k$  объектов, расстояние до которых минимально. Новый объект относится к тому классу, который наиболее часто встречается среди  $k$  ближайших соседей.

Классификация по спектральному углу – это метод определения спектрального сходства между эталонным спектром и спектром гиперспектрального изображения. Спектры каждого из пикселей изображения и референсов представляются в виде  $n$ -мерных векторов (где  $n$  – число спектральных каналов пикселя). Классификация пикселя будет происходить на основании наименьшего угла между вектором пикселя и одного из эталонов.

Метод опорных векторов – алгоритм машинного обучения, используемый для решения задач классификации и регрессии. В задаче классификации SVM работает путем поиска гиперплоскости, которая наилучшим образом разделяет данные на классы. Гиперплоскость выбирается таким образом, чтобы максимизировать разрыв между ближайшими точками (опорными векторами) каждого класса.

Табл. 3. Соотношения обучающей и тестовой выборки

	Обучающая выборка (пкс)	Тестовая выборка (пкс)
Горки и Причал	28224	222517
Маяк и Малое Томылово	11550	109922

Архитектура предлагаемого классификатора M1DCNN включает пять слоев с весами: входной слой, сверточный слой, слой максимального объединения, слой полного соединения и выходной слой. Эти пять слоев применяются для каждой спектральной сигнатуры, чтобы отличить ее от других.

Сеть NM3DCNN представляет собой комбинацию сверточных слоев для анализа одномерных и двумер-

ных срезов гиперспектрального изображения, что позволяет переходить к анализу трехмерных срезов. На вход сети подается гиперкуб, размеры которого определяются количеством каналов  $B$  и пространственными координатами (высотой и шириной)  $H$  и  $W$  соответственно (табл. 4). Такой подход позволяет не только выявить особенности отдельного гиперпикселя, но и найти его взаимозависимости с соседними.

Табл. 4. Структура модифицированной нейронной сети NM3D-DCNN

Фильтр	Количество ядер фильтра	Размерность ядра	Шаг перемещения
Conv1	16	3,3,11	1,1,3
Conv2 1	16	1,1,1	1,1,1
Conv2 2		1,1,3	
Conv2 3		1,1,5	
Conv2 4		1,1,11	
Conv3 1	16	1,1,1	1,1,1
Conv3 2		1,1,3	
Conv3 3		1,1,5	
Conv3 4		1,1,11	
Conv4	16	2,2,3	1,1,1
BatchNorm3d	16	-	-
Pooling	-	2,2,3	2,2,3
Dropout	-	-	-
Linear	5	-	-

Задача классификации интенсивности цветения водорослей в данном исследовании представляет собой задачу бинарной классификации. Поэтому в ка-

честве показателей оценки качества классификации были рассмотрены точность (Accuracy) и F1-score. Основным достоинством Accuracy является легкость

его интерпретации. Однако данная метрика не учитывает распределение данных. Поэтому вводится дополнительная метрика F1-score для оценки качества работы алгоритма на каждом из классов по отдельности. Одновременное использование этих двух метрик может помочь в оценке качества работы моделей.

### 2.3. Понижение спектральной размерности

В связи с тем, что в гиперспектральных изображениях соседние спектральные каналы могут нести схожую информацию, а также из-за небольшого количества данных по сравнению с количеством каналов, приводящих к проклятию размерности [38 – 40], точность работы алгоритмов может снизиться. Для решения этой проблемы в данном исследовании было рассмотрено несколько подходов выбора признаков, основанных на алгоритмах понижения размерности данных, таких как метод главных компонент PCA [39 – 41], метод последовательных неотрицательных проекций SNPA [40 – 42], алгоритм имитационного отжига SAA [41 – 43].

Метод главных компонент широко используется для анализа гиперспектральных изображений, поскольку позволяет описать исходные данные с небольшой потерей информации [39 – 41] с помощью уменьшенного набора некоррелированных переменных – главных компонент ( $PC_i$ ). Главные компоненты являются линейной комбинацией исходных переменных, в данном случае – каналов  $\lambda_j$  гиперспектрального куба:

$$PC_i^j = \sum_{j=1}^n v_{ij} \cdot \lambda_j,$$

где  $v_{ij}$  – коэффициент вклада спектрального канала  $\lambda_j$  в описание главной компоненты  $PC_i$ . Селекция каналов происходит на основании их вклада в описание главных компонент (подробное описание алгоритма в [42]). Поскольку расположенные близко друг к другу спектральные каналы имеют схожий вклад в описание конкретного РС, их можно объединить в несколько спектральных областей. Внутри каждой из областей выбирается представляющий ее спектральный канал с наибольшим абсолютным вкладом. Исходя из суммарного вклада в описание главных компонент, выбираются каналы с наибольшим вкладом  $co_i$ :

$$co_i = \sum_{j=1}^K w_{ij} \cdot a_j,$$

где  $w_{ij}$  – вклад выбранного из области канала в описание  $PC_j$ ,  $a_j$  – вклад  $PC_j$  в описание данных. Было рассмотрено два случая:

- $w_{ij}$  равен вкладу области, из которой был выбран канал [42 – 44] (обозначим PCA v.1);
- $w_{ij}$  равен только вкладу выбранного канала (обозначим PCA v.2).

Метод последовательных неотрицательных проекций представляет собой итеративный подход, осно-

ванный на неотрицательном матричном разложении гиперспектральных данных (NMF):

$$M = WH,$$

где  $M \in \mathbb{R}^{m \times n}$  – изначальное матричное представление гиперспектральных данных,  $m$  – число пикселей,  $n$  – число спектральных каналов,  $W \in \mathbb{R}_+^{m \times r}$  и  $H \in \mathbb{R}_+^{r \times n}$  являются двумя неотрицательными матрицами. Каждая строка матрицы  $M(i, :)$  является спектром пикселя  $i$ . Основная идея алгоритма заключается в представлении спектра каждого из пикселей в виде линейной комбинации  $r$  спектров присутствующих на изображении составляющих материалов, называемых конечными элементами (endmembers). Строки матрицы  $W$  описывают спектры пикселей через конечные элементы, тогда как матрица  $H$  содержит веса этих конечных элементов. Алгоритм итеративно выбирает из матрицы  $M$  спектральный канал, максимизирующий функцию  $f(x) = \|x\|_2^2$ , то есть содержащий наибольшую информацию для описания данных. Такой канал является наиболее репрезентативным для конечных элементов. Далее обновляется матрица весов  $H$  и на ее основании для оставшихся столбцов матрицы  $M$  обновляются значения функции  $f(x)$ . Подробнее об алгоритме можно узнать здесь [40 – 42].

Метод имитационного отжига заключается в поиске состояния системы  $x \in X$  ( $X$  – множество всех состояний), минимизирующего выбранную целевую функцию  $F(x)$  за счет генерации процесса случайного блуждания по пространству состояний  $X$  системы. В данном случае состоянием системы  $x$  является набор спектральных каналов, которые итеративно перебираются для поиска оптимальной конфигурации. За основу был взят подход, реализованный в статье [41 – 43]. На каждой итерации алгоритма в наборе случайным образом меняется один из спектральных каналов, после чего вычисляется целевая функция нового состояния системы. В качестве целевой функции была рассмотрена  $F(x) = 1 - a(x)$ , где  $a(x)$  – точность классификации данных методом  $k$ -ближайших соседей ( $kNN$ ), в который передаются гиперспектральные данные  $x$  с выбранным набором спектральных каналов.

## 3. Результаты и обсуждение

### 3.1. Результаты классификации

Численные результаты классификации вегетационными индексами и алгоритмами представлены в табл. 5, 6 соответственно. Визуальное представление результатов классификации показано на рис. 18, 19.

Из табл. 5, 6 видна существенная разница в качестве классификации для ГСИ «Горки и Причал» и «Маяк и Малое Томылово». Высокие результаты классификации всеми алгоритмами для локации «Горки и Причал» объясняются высокой степенью освещенности локации и разделимости наблюдаемого цветения водорослей. Падение результатов классификации для локации «Маяк и Малое Томылово» возникает по при-

чине низкой освещенности локации и более неявной делимости наблюдаемых объектов.

Рис. 18 демонстрирует, что вегетационные индексы совершают ошибки предсказаний для обоих классов примерно одинаково. Для локации «Маяк и Малое Томылово» OSAVI не справился с задачей разделения классов. NDVI, ChIRI и TCARI не смогли обнаружить границу между двумя классами и, соответственно, между гиперспектральными кубами. NDWI справился с этой задачей, однако сами результаты классификации являются неудовлетворительными. Из табл. 5 видно, что вегетационные индексы плохо

справляются с классификацией интенсивности цветения водорослей в случае низкой освещенности локации и делимости объектов. Среди индексов наилучшие результаты классификации для локации «Горки и Причал» показывает OSAVI и NDWI, а для «Маяк и Малое Томылово» – ChIRI и TCARI. TCARI также показал относительно высокие результаты классификации для первого ГСИ, и данный вегетационный индекс можно рассматривать как более универсальный индекс для классификации интенсивности цветения водорослей в разных условиях освещенности.

Табл. 5. Результаты классификации вегетационными индексами

Местоположение	Вегетационные индексы									
	NDVI [29-31]		NDWI [31-33]		OSAVI [30-32]		TCARI [30-32]		ChIRI [30-32]	
	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %
Горки и Причал	97	97	98	98	98	98	83	83	68	67
Маяк и Малое Томылово	42	42	37	37	54	35	70	69	70	69

Табл. 6. Результаты классификации алгоритмами

Местоположение	Алгоритмы классификации									
	kNN		M1DCNN [34-36]		NM3DCNN [35-37]		SAM [36-38]		SVM [37-39]	
	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %	Acc., %	F-1, %
Горки и Причал	99	99	99	99	99	99	99	99	99	99
Маяк и Малое Томылово	87	87	93	93	91	92	81	80	87	86

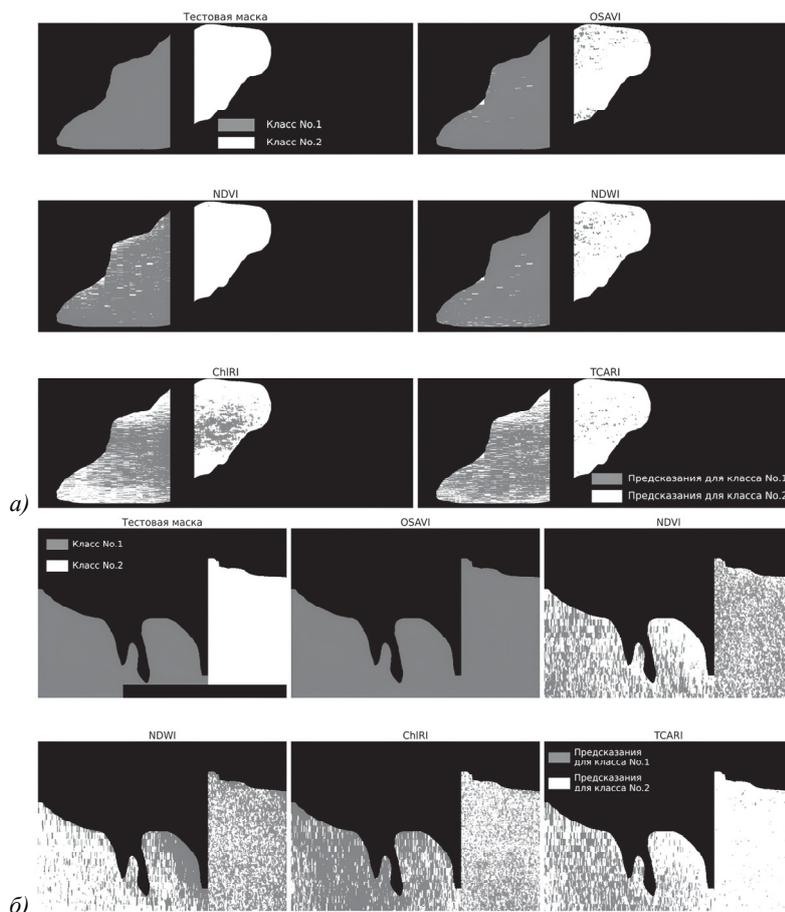


Рис. 18. Визуальное представление результатов классификации вегетационными индексами. а) Горки и Причал, б) Маяк и Малое Томылово

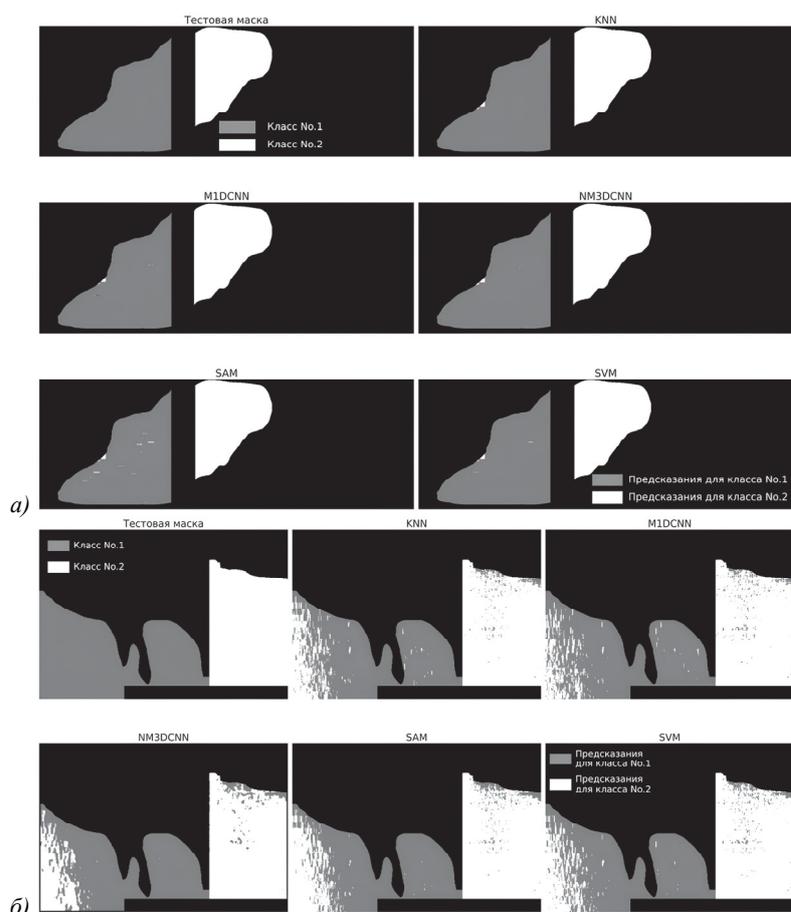


Рис. 19. Визуальное представление результатов классификации алгоритмами.  
а) Горки и Причал, б) Маяк и Малое Томылово

Из рис. 19 видно, что чем ближе друг к другу находятся пиксели разных классов, тем лучше алгоритмы классификации справляются с их разделением. Модели лучше справляются с классификацией пикселей, которым соответствуют области с большей интенсивностью цветения водорослей (в обеих локациях это класс N.2). Табл. 6 демонстрирует большую устойчивость алгоритмов классификации, особенно на основе нейронных сетей, к изменениям параметров среды по сравнению с вегетационными индексами. Для локации «Горки и Причал» все алгоритмы продемонстрировали высокие результаты классификации. В случае ухудшения условий среды наилучшую точность классификации показали сверточные нейронные сети M1DCNN и NM3DCNN.

### 3.2. Результаты селекции спектральных каналов

Поиск наиболее оптимального набора спектральных каналов для описания имеющихся данных происходил в несколько этапов. Сначала для каждого из спектральных кубов были получены наборы спектральных каналов в результате работы алгоритмов на основе PCA, SNPA и SAA. Далее проводился поиск наилучшей спектральной конфигурации для каждого из методов спектральной селекции на основании результатов работы моделей, показавших наилучший

результат классификации на полных данных (M1DCNN и NM3DCNN) (рис. 20). Проведено сравнение результатов классификации до и после селекции каналов (см. табл. 7).

Из рис. 14 видно, что для локации «Горки и Причал» в связи с высокой точностью классификации моделей понижение спектральной размерности не вносит существенных изменений в результаты классификации вне зависимости от рассмотренного количества спектральных каналов. Исходя из результатов для локации «Маяк и Малое Томылово», наименее устойчивыми алгоритмами для спектральной селекции являются SNPA и SAA, показавшие худшие результаты для обеих нейронных сетей. Из табл. 7 видно, что для модели M1DCNN в локации «Маяк и Малое Томылово» все выбранные подходы селекции спектральных каналов привели либо к ухудшению результатов классификации, либо к их сохранению. Из чего можно сделать вывод, что выбранные методики для данной нейронной сети неэффективны. Это может быть связано с архитектурными особенностями модели. Так как нейронная сеть работает по отдельности с каждым спектральным каналом, не учитывая пространственную структуру данных, ее точность предсказаний ухудшается при уменьшении спектральной выборки. Возможно, необходимо рассмотреть нелинейные алго-

ритмы селекции спектральных каналов. Для модели NM3DCNN удалось улучшить качество работы за счет понижения размерности данных алгоритмами на основе PCA и установить наилучший результат классификации среди всех моделей. Сравнивая между собой PCA v.1 и PCA v.2, можно прийти к выводу, что PCA v.1 более предпочтителен, так как показывает лучшие результаты в менее благоприятных условиях работы. Точность классификации в условиях низкой освещенности и разделимости интенсивностей цветения водорослей для связки PCA v.1 – NM3DCNN составила 96,3%, а F1-score – 96,6%. Проведение прямого срав-

нения результатов решения поставленной задачи классификации интенсивности цветения водорослей с аналогичными исследованиями не представляется возможным по причине отличающихся постановок задач и условий проведения экспериментов, таких как исследуемая область, имеющийся объем данных и т. д. В работе [24] модель осуществляла идентификацию водорослей в летне-осенний период с точностью 93,4%. В работе [26] общая точность классификации доминирующих видов водорослей с помощью метода максимального правдоподобия составила 95,1%, а с помощью SAM – 87,9%.

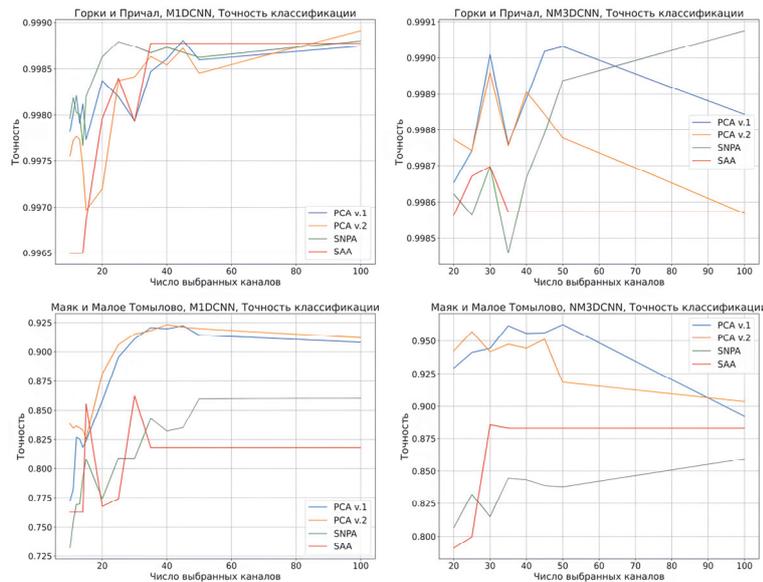


Рис. 20. Результаты работы моделей в зависимости от данных и выбранного набора спектральных каналов

Табл. 7. Результаты работы моделей с пониженным количеством каналов для разных алгоритмов селекции

Локация	Модель	Метод	Accuracy	F1-score	Количество каналов
Горки и Причал	M1DCNN	PCA v.1	0,9988	0,9990	45
		PCA v.2	<b>0,9989</b>	<b>0,9991</b>	100
		SNPA	0,9988	0,9991	100
		SAA	0,9988	0,9990	35
		Baseline	<b>0,9988</b>	<b>0,9990</b>	-
	NM3DCNN	PCA v.1	0,9990	0,9992	50
		PCA v.2	0,9990	0,9991	30
		SNPA	<b>0,9990</b>	<b>0,9992</b>	100
		SAA	0,9987	0,9989	30
		Baseline	<b>0,9987</b>	<b>0,9989</b>	-
Маяк и Малое Томылово	M1DCNN	PCA v.1	0,922	0,930	45
		PCA v.2	<b>0,923</b>	<b>0,931</b>	40
		SNPA	0,861	0,862	50
		SAA	0,862	0,870	15
		Baseline	<b>0,929</b>	<b>0,930</b>	-
	NM3DCNN	PCA v.1	<b>0,963</b>	<b>0,966</b>	50
		PCA v.2	0,957	0,961	25
		SNPA	0,860	0,860	100
		SAA	0,885	0,889	30
		Baseline	<b>0,913</b>	<b>0,916</b>	-

**Заключение**

В ходе выполнения задачи анализа состояния речных вод был выработан подход к анализу гиперспек-

тральных изображений высокого пространственного разрешения. Анализ ГСИ воды показал разницу в средних спектрах участков реки с разной интенсивностью цветения водорослей. Рассмотрены различ-

ные подходы классификации интенсивности цветения водорослей в разных участках водоема: с помощью вегетационных индексов и алгоритмов. Сравнение подходов продемонстрировало эффективность применения алгоритмов, особенно на основе глубокого обучения, по сравнению с вегетационными индексами. Нейронные сети M1DCNN и NM3DCNN продемонстрировали наилучшую точность классификации при разных условиях освещенности и разделимости водорослей. Эти методы могут быть использованы для регулярного мониторинга состояния воды. Были рассмотрены различные алгоритмы понижения спектральной размерности данных для моделей M1DCNN и NM3DCNN. Для модели M1DCNN понижение спектральной размерности не принесло улучшения результатов работы. Для NM3DCNN понижение размерности повысило качество классификации при экономии использования оперативной памяти и ускорении вычислений. Наиболее эффективными показали себя алгоритмы на основе PCA. Связка PCA v.1 – NM3DCNN показала наилучшую точность классификации ГСИ среди рассмотренных подходов в условиях низкой освещенности и разделимости объектов, в связи с чем эта связка может быть использована в дальнейших исследованиях обнаружения загрязнения водных ресурсов.

#### **Благодарности**

Техническая и экспериментальная части исследования выполнены при поддержке Министерства науки и высшего образования Российской Федерации (Проект FSSS-2024-0022 (регистрационный номер: 1023112900147-4 от 31.01.24)). Теоретическая часть исследования осуществлена в рамках гранта Российского научного фонда №22-19-00364.

#### **References**

- [1] Ritchie JC, Zimba PV, Everitt JH. Remote sensing techniques to assess water quality. *Photogramm Eng Remote Sens* 2003; 6: 695-704. DOI: 10.14358/PERS.69.6.695.
- [2] Fan C. Spectral analysis of water reflectance for hyperspectral remote sensing of water quality in estuarine water. *Journal of Geoscience and Environment Protection* 2014; 2: 19-27. DOI: 10.4236/gep.2014.22004.
- [3] Illarionova S, Shadrin D, Tregubova P, Ignatiev V, Efimov A, Oseledets I, Burnaev E. A survey of computer vision techniques for forest characterization and carbon monitoring tasks. *Remote Sens* 2022; 14(22): 5861. DOI: 10.3390/rs14225861.
- [4] Chandler O, Young F, Maraseni T, Apan A. Opportunities and limitations of remote sensing for crop loss (hail damage) assessment in the insurance industry. 2005. Source: <[https://www.researchgate.net/publication/228863171\\_Opportunities\\_and\\_limitations\\_of\\_remote\\_sensing\\_for\\_crop\\_loss\\_hail\\_damage\\_assessment\\_in\\_the\\_insurance\\_industry#read](https://www.researchgate.net/publication/228863171_Opportunities_and_limitations_of_remote_sensing_for_crop_loss_hail_damage_assessment_in_the_insurance_industry#read)>.
- [5] Chen Y, Fan R, Yang X, Wang J, Latif A. "Extraction of urban water bodies from high-resolution remote-sensing imagery using deep learning. *Water* 2018; 10(5): 585. DOI: 10.3390/w10050585.
- [6] Avdan ZY, Kaplan G, Goncu S, Avdan U. Monitoring the water quality of small water bodies using high-resolution remote sensing data. *ISPRS Int J Geo-Inf* 2019; 8(12): 553. DOI: 10.3390/ijgi8120553.
- [7] Illarionova S, Nesteruk S, Shadrin D, Ignatiev V, Pukalchik M, Oseledets I. MixChannel: Advanced Augmentation for Multispectral Satellite Images. *Remote Sens* 2021; 13(11): 2181. DOI: 10.3390/rs13112181.
- [8] Chen J, Wang J, Feng S, Zhao Z, Wang M, Sun C, Song N, Yang J. Study on parameter inversion model construction and evaluation method of UAV hyperspectral urban inland water pollution dynamic monitoring. *Water* 2023; 15(23): 4131. DOI: 10.3390/w15234131.
- [9] Podlipnov VV, Shchedrin VN, Babichev AN, Vasilyev SM, Blank VA. Experimental determination of soil moisture on hyperspectral images. *Computer Optics* 2018; 42(5): 877-884. DOI: 10.18287/2412-6179-2017-42-5-877-884.
- [10] Kazanskiy NL, Kharitonov SI, Karsakov AV, Khonina SN. Modeling action of a hyperspectrometer based on the Offner scheme within geometric optics. *Computer Optics* 2014; 38(2): 271-280. DOI: 10.18287/0134-2452-2014-38-2-271-280.
- [11] Popandopulo G, Illarionova S, Shadrin D, Evteeva K, Sotiriadi N, Burnaev E. Flood extent and volume estimation using remote sensing data. *Remote Sens* 2023; 15(18): 4463. DOI: 10.3390/rs15184463.
- [12] Elshorbagy W, Chowdhury RK. *Water treatment*. Rijeka: IntechOpen; 2013. ISBN: 978-953-51-0928-0.
- [13] Park Y, Pyo JC, Kwon Y, Cha Y, Lee H, Kang T, Cho K. Evaluating physico-chemical influences on cyanobacterial blooms using hyperspectral images in Inland Water, Korea. *Water Res* 2017; 126: 319-328. DOI: 10.1016/j.watres.2017.09.026.
- [14] Yang C, Everitt J, Bradford J. Use of spectral angle mapper (SAM) and hyperspectral imagery for yield estimation. 2006. Source: <<https://elibrary.asabe.org/abstract.asp?JID=5&AID=20649&CID=por2006&T=1>>. DOI: 10.13031/2013.20649.
- [15] Kiage LM, Walker ND. Using NDVI from MODIS to monitor duckweed bloom in Lake Maracaibo, Venezuela. *Water Resour Manag* 2009; 23(6): 1125-1135. DOI: 10.1007/s11269-008-9318-9.
- [16] Zhang T, Hu H, Ma X, Zhang Y. Long-term spatiotemporal variation and environmental driving forces analyses of algal blooms in Taihu Lake based on multi-source satellite and land observations. *Water* 2020; 12(4): 1035. DOI: 10.3390/w12041035.
- [17] Adamiak M, Będkowski K, Majchrowska A. Aerial imagery feature engineering using bidirectional generative adversarial networks: A case study of the Pilica River Region, Poland. *Remote Sens* 2021; 13(02): 306. DOI: 10.3390/rs13020306.
- [18] Ghaderi D, Rahbani M. Tracing suspended matter in Tiab Estuary applying ANN and remote sensing. *Reg Stud Mar Sci* 2021; 44: 101788. DOI: 10.1016/j.rsma.2021.101788.
- [19] He Z, Wen X, Liu H, Du J. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the Semiarid Mountain Region. *J Hydrol* 2014; 509: 379-386. DOI: 10.1016/j.jhydrol.2013.11.054.
- [20] Boyer JN, Kelble CR, Ortner PB, Rudnick DT. Phytoplankton bloom status: Chlorophyll *a* biomass as an indicator of water quality condition in the southern estuaries of Florida, USA. *Ecol Indic* 2009; 9(6, Suppl): S56-S67. DOI: 10.1016/j.ecolind.2008.11.013.

- [21] Park Y, Cho KH, Park J, Cha SM, Kim JH. Development of early-warning protocol for predicting chlorophyll-a concentration using machine learning models in freshwater and estuarine reservoirs, Korea. *Sci Total Environ* 2015; 502: 31-41. DOI: 10.1016/j.scitotenv.2014.09.005.
- [22] Yan H, Zhang J, Rahman SS, Zhou N, Suo Y. Predicting permeability changes with injecting CO<sub>2</sub> in coal seams during CO<sub>2</sub> geological sequestration: a comparative study among six SVM-based hybrid models. *Sci Total Environ* 2020; 705: 135941. DOI: 10.1016/j.scitotenv.2019.135941.
- [23] Aleshin M, Illarionova S, Shadrin D, Ivanov V, Vanovskiy V, Burnaev E. Machine learning-based modeling of chl-a concentration in Northern marine regions using oceanic and atmospheric data. *Front Mar Sci* 2024; 11: 1412883. DOI: 10.3389/fmars.2024.1412883.
- [24] Zhu S, Wu Y, Ma X. Deep learning-based algal bloom identification method from remote sensing images – Take China’s Chaohu Lake as an example. *Sustainability* 2023; 15(05): 4545. DOI: 10.3390/su15054545.
- [25] Oppelt NM, Schulze F, Doernhoefer K, Eisenhardt I, Bartsch I. Hyperspectral classification approaches for intertidal macroalgae habitat mapping: A case study in Heligoland. *Optical Engineering* 2012; 51(11): 111703. DOI: 10.1117/1.OE.51.11.111703.
- [26] Diruit W, Bris A, Bajjouk T, Richier S, Helias M, Burel T, Lennon M, Guyot A, Gall E. Seaweed habitats on the shore: Characterization Through Hyperspectral UAV imagery and field sampling. *Remote Sens* 2022; 14(13): 3124. DOI: 10.3390/rs14133124.
- [27] Lin Y, Gao J, Tu Y, Zhang Y, Gao J. Estimating low concentration heavy metals in water through hyperspectral analysis and genetic algorithm-partial least squares regression. *Sci Total Environ* 2024; 916: 170225. DOI: 10.1016/j.scitotenv.2024.170225.
- [28] Mu T, Han F, Bao D, Zhang C, Liang R. Compact snapshot optically replicating and remapping imaging spectrometer (ORRIS) using a focal plane continuous variable filter. *Opt Lett* 2019. 44(5): 1281-1284. DOI: 10.1364/OL.44.001281.
- [29] Sweeney DW, Sommargren GE. Harmonic diffractive lenses. *Appl Opt* 1995; 34(14): 2469-2475. DOI: 10.1364/AO.34.002469.
- [30] Malmir M, Tahmasbian I, Xu Z, Farrar M, Bai SH. Prediction of soil macro-and micro-elements in sieved and ground air-dried soils using laboratory-based hyperspectral imaging technique. *Geoderma* 2019; 340: 70-80. DOI: 10.1016/j.geoderma.2018.12.049.
- [31] Becker F, Choudhury BJ. Relative Sensitivity of Normalized Difference Vegetation Index (NDVI) and Microwave Polarization Difference Index (MPDI) for vegetation and desertification monitoring. *Remote Sens Environ* 1988; 24(2): 297-311. DOI: 10.1016/0034-4257(88)90031-4.
- [32] Savorskiy V, Kashnitskii A, Konstantinova AM, Balashov IV, Krasheninnikova YuS, Tolpin V, Maklakov S, Savchenko E. Capabilities of hyperspectral indices analysis of the vega-constellation remote monitoring information systems. *Current Problems in Remote Sensing of the Earth from Space* 2016; 13: 28-45. DOI: 10.21046/2070-7401-2016-13-3-28-45.
- [33] McFeeters SK. The use of the normalized difference water index (NDWI) in the delineation of open water features. *Int J Remote Sens* 1996; 17(7): 1425-1432. DOI: 10.1080/01431169608948714.
- [34] Barnes RJ, Dhanoa MS, Lister SJ. Standard normal variate transformation and De-trending of near-infrared diffuse reflectance spectra. *Applied Spectroscopy* 1989; 43(5): 772-777. DOI: 10.1366/0003702894202201.
- [35] Rota G-C. The advanced theory of statistics: M. G. Kendall and A. Stuart, 3 vols., 4th ed., Macmillan, 1977-1983. *Adv Math* 1986; 60(1): 123. DOI: 10.1016/0001-8708(86)90015-0.
- [36] Hu W, Huang Y, Li W, Zhang F, Li H. Deep convolutional neural networks for hyperspectral image classification. *J Sens* 2015; 2015(1): 258619. DOI: 10.1155/2015/258619.
- [37] Firsov NA, Podlipnov VV, Ivliev NA, Nikolaev PP, Mashkov SV, Ishkin PA, Skidanov RV, Nikonorov AV. Neural network-aided classification of hyperspectral vegetation images with a training sample generated using an adaptive vegetation index. *Computer Optics* 2021; 45(6): 887-896. DOI: 10.18287/2412-6179-CO-1038.
- [38] Kruse FA, Lefkoff AB, Boardman JW, Heidebrecht KB, Shapiro A, Barloon PJ, Goetz AFH. The Spectral Image Processing System (SIPS) – interactive visualization and analysis of imaging spectrometer data. *Remote Sens Environ* 1993; 44(2-3): 145-163. DOI: 10.1016/0034-4257(93)90013-N.
- [39] Awad M, Khanna R. Support vector machines for classification. In Book: Awad M, Khanna R, eds. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*. New York: Springer Science+Business Media; 2015: 39-66. DOI: 10.1007/978-1-4302-5990-9\_3.
- [40] Hughes GP. On the mean accuracy of statistical pattern recognizers. *IEEE Trans Inf Theory* 1968; 14(1): 55-63. DOI: 10.1109/TIT.1968.1054102.
- [41] Rodarmel C, Shan J. Principal component analysis for hyperspectral image classification. *Surv Land Inf Syst* 2002; 62(2): 115-123.
- [42] Gillis N. Successive nonnegative projection algorithm for robust nonnegative blind source separation. *SIAM Journal on Imaging Sciences* 2014; 7(2). Source: <<https://epubs.siam.org/doi/10.1137/130946782>>. DOI: 10.1137/130946782.
- [43] Chauvin J, Duran R, Tavakolian K, et al. Simulated annealing-based hyperspectral data optimization for fish species classification: Can the number of measured wavelengths be reduced? *Appl Sci* 2021; 11(22): 10628. DOI: 10.3390/app112210628.
- [44] Centeno JAS, Kern J, Mitishita EA, Palma MEJ. PCA band selection method for a hyperspectral sensors onboard an UAV. *ISPRS Ann Photogramm Remote Sens Spat Inf Sci* 2020; IV-3/W2-2020: 77-81. DOI: 10.5194/isprs-annals-IV-3-W2-2020-77-2020.

### Сведения об авторах

**Новиков Илья Алексеевич**, аспирант направления «Вычислительные системы и анализ данных в науке и технике» Сколковского института науки и технологий. Работает инженером-исследователем в центре прикладного искусственного интеллекта Сколтех. E-mail: [il.novikov@skoltech.ru](mailto:il.novikov@skoltech.ru)

**Макаров Андрей Романович**, аспирант кафедры суперкомпьютеров и общей информатики Самарского университета, работает инженером в лаборатории интеллектуального анализа видеоданных Института систем обработки изображений, НИЦ «Курчатовский институт». E-mail: [andre.makar1999@gmail.com](mailto:andre.makar1999@gmail.com)

**Подлипов Владимир Владимирович**, инженер НИЛ-35 Самарского национального исследовательского университета, научный сотрудник лаборатории микро- и нанотехнологий Института систем обработки изображений, НИЦ «Курчатовский институт». E-mail: [podlipnovvv@ya.ru](mailto:podlipnovvv@ya.ru)

**Платонов Владимир Игоревич**, кандидат химических наук, доцент кафедры химии Самарского национального исследовательского университета им. академика С.П. Королева, исполняющий обязанности заведующего кафедрой экологии и безопасности жизнедеятельности Самарского национального исследовательского университета им. академика С.П. Королева. E-mail: [rovvv@yandex.ru](mailto:rovvv@yandex.ru)

**Рыськова Дарья Дмитриевна**, в настоящее время студентка Самарского национального исследовательского университета им. академика С.П. Королева по специальности «Прикладная математика и физика». E-mail: [ddryskova2002@gmail.com](mailto:ddryskova2002@gmail.com)

**Калашникова Ольга Владимировна**, кандидат биологических наук, доцент кафедры экологии и безопасности жизнедеятельности и начальник отдела конгрессно-выставочной деятельности Самарского национального исследовательского университета им. академика С.П. Королева, директор АНО «Экологический центр Поволжья». E-mail: [kalashnikova.ov@ssau.ru](mailto:kalashnikova.ov@ssau.ru)

**Хабибуллин Роман Маратович**. Кандидат технических наук, старший научный сотрудник института искусственного интеллекта Самарского национального исследовательского университета им. академика С.П. Королева, научный сотрудник лаборатории интеллектуального анализа Института систем обработки изображений, НИЦ «Курчатовский институт». E-mail: [khabibullin.rm@ssau.ru](mailto:khabibullin.rm@ssau.ru)

**Скиданов Роман Васильевич**, с отличием окончил (1990) Самарский национальный исследовательский университет им. академика С.П. Королева по специальности «Физика». Доктор физико-математических наук (2007). Заведующий лабораторией микро- и нанотехнологий Института систем обработки изображений, НИЦ «Курчатовский институт», по совместительству профессор кафедры технической кибернетики Самарского национального исследовательского университета им. академика С.П. Королева. Соавтор 260 научных работ, 10 монографий. E-mail: [romans@ipsiras.ru](mailto:romans@ipsiras.ru)

**Илларионова Светлана Владимировна**, PhD в области науки о данных. Работает научным сотрудником в Сколковском институте науки и технологий. E-mail: [s.illarionova@skoltech.ru](mailto:s.illarionova@skoltech.ru)

**Выборнова Юлия Дмитриевна**, в 2015 году окончила Самарский государственный аэрокосмический университет им. академика С.П. Королева. В 2019 году защитила диссертацию на соискание ученой степени кандидата технических наук. Работает старшим научным сотрудником в институте искусственного интеллекта Самарского национального исследовательского университета имени академика С. П. Королёва. Область научных интересов: защита данных, криптография, цифровые водяные знаки, обработка изображений. E-mail: [ybornovamail@gmail.com](mailto:ybornovamail@gmail.com)

**Никоноров Артём Владимирович**. В 2005 году окончил Самарский национальный исследовательский университет им. академика С.П. Королева. Доктор технических наук (2016). В настоящее время работает профессором кафедры суперкомпьютеров и общей информатики Самарского национального исследовательского университета им. академика С.П. Королева, ведущим научным сотрудником в лаборатории интеллектуального анализа видеоданных Института систем обработки изображений, НИЦ «Курчатовский институт». Опубликовал более 90 работ, две монографии. E-mail: [artniko@gmail.com](mailto:artniko@gmail.com)

**Шадрин Дмитрий Германович**, PhD в области науки о данных. Начальник отдела в Сколковском институте науки и технологий. E-mail: [d.shadrin@skoltech.ru](mailto:d.shadrin@skoltech.ru)

**Подладчикова Татьяна Владимировна**, кандидат технических наук, директор Центра системного проектирования Сколковского института науки и технологий. E-mail: [t.podladchikova@skoltech.ru](mailto:t.podladchikova@skoltech.ru)

---

ГРНТИ: 28.23.15

Поступила в редакцию 11 апреля 2024 г. Окончательный вариант – 24 декабря 2024 г.

---

---

# Algae bloom intensity classification using machine learning methods and UAV hyperspectral data

I.A. Novikov<sup>1</sup>, A.R. Makarov<sup>2,3</sup>, V.V. Podlipnov<sup>2,3</sup>, V.I. Platonov<sup>3</sup>, D.D. Ryskova<sup>3</sup>, O.V. Kalashnikova<sup>3</sup>,  
R.M. Khabibullin<sup>2,3</sup>, R.V. Skidanov<sup>2,3</sup>, S.V. Illarionova<sup>1</sup>, Y.V. Vybornova<sup>3</sup>, A.V. Nikonov<sup>2,3</sup>, D.G. Shadrin<sup>1</sup>,  
T.V. Podladchikova<sup>1</sup>

<sup>1</sup> Skolkovo Institute of Science and Technology, Bolshoy Boulevard, 30, Bld. 1, Skolkovo, 121205, Moscow, Russia;

<sup>2</sup> Institute of Image Processing Systems, NRC "Kurchatov Institute,"  
Molodogvardeyskaya Str. 151, Samara, 443001, Russia;

<sup>3</sup> Samara National Research University named after academician S.P. Korolyov,  
Moskovskoye Shosse 34, Samara, 443086, Russia

## Abstract

This paper presents an approach for high spatial resolution hyperspectral image analysis in an applied task of river water condition assessment. The method allows the detection of algal blooms or water pollution by foreign substances. High-resolution hyperspectral images were obtained using a hyperspectrometer mounted on a small unmanned aerial vehicle. A difference between the spectra of river parts with varying intensity of algal blooms was demonstrated. Water samples were taken, and chemical analysis confirmed the varying levels of magnesium and calcium across all samples, corresponding to the intensity of algal blooms in the water. Several machine learning-based classification algorithms and vegetation indices were considered for classifying water areas with varying intensities of algal blooms. The effectiveness of machine learning algorithms compared to vegetation indices was shown. In addition, to improve the performance of the most effective classification algorithms, a comparison of several dimensionality reduction approaches based on spectral channel selection was carried out.

**Keywords:** hyperspectrometer, spectral analysis, hyperspectral images, index images, machine learning.

**Citation:** Novikov IA, Makarov AR, Podlipnov VV, Platonov VI, Ryskova DD, Kalashnikova OV, Khabibullin RM, Skidanov RV, Illarionova SV, Vybornova YV, Nikonov AV, Shadrin DG, Podladchikova TV. Algae bloom intensity classification using machine learning methods and UAV hyperspectral data. *Computer Optics* 2025; 49(6): 972-985. DOI: 10.18287/2412-6179-CO-1539.

**Acknowledgements:** The technical and experimental parts of the study were funded by the Ministry of Science and Higher Education of the Russian Federation Project FSSS-2024-0022 (registration number: 1023112900147-4 dated 31.01.24). The theoretical part of the study was funded by the Russian Science Foundation under grant No 22-19-00364.

---

## Author's information

**Ilya Alekseevich Novikov**, is a Ph.D. student in "Computational and Data Science and Engineering" program from the Skolkovo Institute of Science and Technology. He works as a research engineer at the Skoltech Center for Applied Artificial Intelligence. E-mail: [il.novikov@skoltech.ru](mailto:il.novikov@skoltech.ru)

**Andrey Romanovich Makarov**, is a Ph.D. student at the Department of Supercomputing and General Informatics of Samara University. He works as an engineer in the Laboratory of Intelligent Video Data Analysis at the Institute of Image Processing Systems, NRC "Kurchatov Institute". E-mail: [andre.makar1999@gmail.com](mailto:andre.makar1999@gmail.com)

**Vladimir Vladimirovich Podlipnov**, is an engineer at R&D Lab-35 of Samara National Research University and a researcher at the Micro- and Nanotechnology Laboratory of the Institute of Image Processing Systems, NRC "Kurchatov Institute". E-mail: [podlipnovvv@ya.ru](mailto:podlipnovvv@ya.ru)

**Vladimir Igorevich Platonov**, Ph.D. in Chemistry, is an Associate Professor at the Department of Chemistry, Samara National Research University named after Academician S.P. Korolyov, and currently serves as Acting Head of the Department of Ecology and Life Safety at the same university. E-mail: [rovvv@yandex.ru](mailto:rovvv@yandex.ru)

**Daria Dmitrievna Ryskova**, is currently a student at Samara National Research University named after Academician S.P. Korolyov, specializing in "Applied Mathematics and Physics." E-mail: [ddryskova2002@gmail.com](mailto:ddryskova2002@gmail.com)

**Olga Vladimirovna Kalashnikova**, Ph.D. in Biological Sciences, is an Associate Professor at the Department of Ecology and Life Safety and Head of the Congress and Exhibition Department at Samara National Research University named after Academician S.P. Korolyov. She is also the Director of the Volga Region Environmental Center. E-mail: [kalashnikova.ov@ssau.ru](mailto:kalashnikova.ov@ssau.ru)

**Roman Maratovich Khabibullin**, holds a Ph.D. in Engineering, and is a Senior Researcher at the Institute of Artificial Intelligence, Samara National Research University named after Academician S.P. Korolyov. He is also a researcher at the Laboratory of Intelligent Analysis at the Institute of Image Processing Systems, NRC "Kurchatov Institute". E-mail: [khabibullin.rm@ssau.ru](mailto:khabibullin.rm@ssau.ru)

**Roman Vasilyevich Skidanov**, graduated with honors in 1990 from Samara National Research University named after Academician S.P. Korolyov, majoring in "Physics." He earned his Doctor of Physical and Mathematical Sciences degree in 2007. He is the Head of the Micro- and Nanotechnology Laboratory at the Institute of Image Processing Systems, NRC "Kurchatov Institute," and concurrently a Professor at the Department of Technical Cybernetics at Samara National Research University named after Academician S.P. Korolyov. He is the co-author of 260 scientific works and 10 monographs. E-mail: [romans@ipsiras.ru](mailto:romans@ipsiras.ru)

**Svetlana Vladimirovna Illarionova**, holds a Ph.D. in Data Science. She works as a research scientist at the Skolkovo Institute of Science and Technology. E-mail: [s.illarionova@skoltech.ru](mailto:s.illarionova@skoltech.ru)

**Yulia Dmitrievna Vybornova**, graduated in 2015 from Samara State Aerospace University named after Academician S.P. Korolyov. In 2019, she defended her dissertation for the degree of Candidate of Technical Sciences. She works as a Senior Researcher at the Institute of Artificial Intelligence, Samara National Research University named after Academician S.P. Korolyov. Her research interests include data protection, cryptography, digital watermarks, and image processing. E-mail: [vybornovamail@gmail.com](mailto:vybornovamail@gmail.com)

**Artem Vladimirovich Nikonov**, graduated in 2005 from Samara National Research University named after Academician S.P. Korolyov. He earned his Doctor of Technical Sciences degree in 2016. He is currently a Professor at the Department of Supercomputing and General Informatics at Samara National Research University named after Academician S.P. Korolyov, and a leading researcher at the Laboratory of Intelligent Video Data Analysis at the Institute of Image Processing Systems, NRC "Kurchatov Institute." He has published over 90 papers and two monographs. E-mail: [artniko@gmail.com](mailto:artniko@gmail.com)

**Dmitry Germanovich Shadrin**, holds a Ph.D. in Data Science. He is the Head of a department at the Skolkovo Institute of Science and Technology. E-mail: [d.shadrin@skoltech.ru](mailto:d.shadrin@skoltech.ru)

**Tatyana Vladimirovna Podladchikova**, Ph.D. in Engineering, is the Director of the Center for System Design at the Skolkovo Institute of Science and Technology. E-mail: [t.podladchikova@skoltech.ru](mailto:t.podladchikova@skoltech.ru)

---

*Received April 11, 2024. The final version – December 24, 2024.*

---