

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное учреждение науки
Хабаровский федеральный исследовательский центр
Дальневосточного отделения Российской академии наук



На правах рукописи

Дубровин Константин Николаевич

Разработка методики мониторинга пахотных земель Дальнего Востока
на основе данных дистанционного зондирования Земли и машинного обучения

1.6.19. Аэрокосмические исследования Земли, фотограмметрия

Диссертация на соискание ученой степени кандидата
технических наук

Научный руководитель –
доктор фармацевтических наук
Степанов Алексей Сергеевич

Хабаровск – 2025

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	5
1 ПРИМЕНЕНИЕ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ ДЛЯ РЕШЕНИЯ ЗАДАЧ МОНИТОРИНГА ПАХОТНЫХ ЗЕМЕЛЬ	12
1.1 Задачи мониторинга сельскохозяйственных земель	12
1.2 Современные спутниковые системы и получение данных для сельскохозяйственного мониторинга	13
1.2.1 Спутниковые аппараты	13
1.2.2 Вегетационные индексы	15
1.3 Анализ существующих методов использования данных дистанционного зондирования Земли для решения задач сельского хозяйства	18
1.3.1 Идентификация посевов сельскохозяйственных культур и составление карт пахотных земель	18
1.3.2 Прогнозирование урожайности сельскохозяйственных культур	31
1.4 Выводы по первому разделу	35
2 АЛГОРИТМЫ РАСПОЗНАВАНИЯ ПОСЕВОВ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР И НЕИСПОЛЬЗУЕМЫХ ПАХОТНЫХ ЗЕМЕЛЬ С ИСПОЛЬЗОВАНИЕМ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ	38
2.1 Получение и предварительная обработка данных	40
2.1.1 Область исследования	40
2.1.2 Получение спутниковых данных	43
2.1.3 Формирование непрерывных временных рядов NDVI	45
2.2 Сезонный ход NDVI и фенология сельскохозяйственных культур	49
2.3 Машинное обучение и оценка точности карт	56
2.3.1 Формирование датасетов для обучения	56

2.3.2	Машинное обучение для решения задачи классификации	59
2.3.3	Оценка точности классификации	61
2.4	Выводы по второму разделу	62
3 АНАЛИЗ РЕЗУЛЬТАТОВ РАСПОЗНАВАНИЯ ПОСЕВОВ		
СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР И НЕИСПОЛЬЗУЕМЫХ		
ПАХОТНЫХ ЗЕМЕЛЬ		
		64
3.1	Оценка точности построения карт пахотных земель в Хабаровском крае в 2021–2023 гг.	64
3.1.1	Построение масок сельскохозяйственных культур по полным сезонным временным рядам NDVI	64
3.1.2	Результаты раннего распознавания посевов сельскохозяйственных культур и неиспользуемой пашни	74
3.2	Результаты автоматизированного картографирования земель сельскохозяйственного назначения Хабаровского района в 2019–2020 гг. по многолетним спутниковым данным	82
3.2.1	Использование результатов классификации для оценки площадей, занятых посевами сои. Сравнение полученных результатов с данными официальной статистики	82
3.2.2	Использование результатов классификации для оценки площади неиспользуемых пахотных земель	88
3.3	Использование рядов радиолокационного вегетационного индекса DpRVI для распознавания посевов сельскохозяйственных культур	91
3.3.1	Область исследования и исходные данные	92
3.3.2	Машинное обучение и оценка точности	94
3.3.3	Анализ сезонного хода DpRVI для исследуемых классов	94
3.3.4	Результаты распознавания посевов сельскохозяйственных культур и неиспользуемой пашни с использованием рядов DpRVI	96

3.4 Выводы по третьему разделу	100
4 ПРОГНОЗИРОВАНИЕ УРОЖАЙНОСТИ СОИ НА МУНИЦИПАЛЬНОМ УРОВНЕ С ИСПОЛЬЗОВАНИЕМ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ.....	102
4.1 Прогнозирование урожайности сои с использованием максимального сезонного значения NDVI и метеорологических характеристик	102
4.1.1 Построение модели сезонного хода NDVI для пашни	103
4.1.2 Построение регрессионной модели для прогнозирования урожайности на районном уровне.....	108
4.2 Раннее прогнозирование урожайности сои с использованием значений NDVI и количества дней вегетации	112
4.2.1 Область исследования.....	113
4.2.2 Принципы построения моделей для раннего прогнозирования урожайности	114
4.2.3 Прогнозирование значения максимума вегетации	116
4.2.4 Прогнозирование урожайности сои в районах ЕАО с использованием расчётных максимумов NDVI	117
4.3 Выводы по четвертому разделу	120
ЗАКЛЮЧЕНИЕ	122
СПИСОК ЛИТЕРАТУРЫ	124
ПРИЛОЖЕНИЕ А (обязательное) АКТ ВНЕДРЕНИЯ РЕЗУЛЬТАТОВ В РАМКАХ НАУЧНО- ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЫ ПО ГОСУДАРСТВЕННОМУ КОНТРАКТУ	146
ПРИЛОЖЕНИЕ Б (обязательное) АКТ О ВНЕДРЕНИИ НАУЧНЫХ РАЗРАБОТОК В ДЕЯТЕЛЬНОСТЬ	148

ВВЕДЕНИЕ

Актуальность темы исследования. Эффективное использование земель сельскохозяйственного назначения является важным условием поступательного развития агропромышленного комплекса (АПК) на Дальнем Востоке России. В соответствии со стратегией социально-экономического развития Дальнего Востока и Байкальского региона, до 2025 г. планируется повысить роль экспортной составляющей в производстве зерновых и зернобобовых культур, для чего необходимо решить задачу планирования необходимых посевных площадей.

На текущий момент, во-первых, существующие федеральные и региональные базы данных о землях сельскохозяйственного назначения (ЗСН) содержат достаточно большое количество некорректных данных, во-вторых, собственники и арендаторы ЗСН, в том числе иностранные предприятия, зачастую предоставляют недостоверную информацию, в-третьих, для Дальнего Востока характерно наличие значительного объема заброшенных пахотных земель, что не отражено на существующих картах. При этом наземная визуальная экспертиза – это достаточно затратное мероприятие, а в ретроспективном периоде – невозможное. Решение вопросов сбора и обработки данных для макрорегиона осложняется большой площадью территории, что приводит к необходимости обработки разновременных спутниковых снимков и построению композитов. Дополнительную сложность для исследователей создают особенности климата южной части Дальнего Востока (большое количество облачных дней в ходе периода вегетации), что делает особенно актуальной задачу построения непрерывных временных рядов спутниковых данных.

Разработка методических подходов для распознавания посевов сельскохозяйственных культур с использованием машинного обучения и моделирование вегетационных циклов их развития является актуальной задачей в связи с отсутствием комплексных исследований в этой области, учитывающих особенности региона. Спутниковый мониторинг позволяет как восстанавливать сведения о севообороте на сельскохозяйственных полях (что особенно важно для регионов Дальнего Востока, где наблюдается острый дефицит архивных данных), так и создавать каче-

ственные карты пахотных земель в оперативном режиме (в течение сельскохозяйственного сезона). Высокую значимость для науки имеет изучение возможности использования для классификации пахотных земель, наряду с оптическими, также и данных радиолокации, что способствует решению ряда проблем, связанных с облачными явлениями.

К актуальным направлениям исследований относится разработка принципов построения моделей раннего прогнозирования урожайности сельскохозяйственных культур на основе методов дистанционного зондирования Земли (ДЗЗ) на муниципальном и региональном уровне. Построение регрессионных моделей с использованием данных ДЗЗ позволяет оценивать урожайность сельскохозяйственных культур уже в середине сельскохозяйственного сезона. Оперативное получение детальных карт пахотных земель и раннее прогнозирование урожайности способствует получению предварительных оценок валового сбора сельскохозяйственных культур, финансовых рисков, заблаговременному планированию посевных площадей и мер поддержки сельскохозяйственных производителей.

Степень разработанности темы. Основными отечественными научными и образовательными организациями, ведущими исследования в области спутникового мониторинга сельскохозяйственных земель, являются: Институт космических исследований РАН, Агрофизический научно-исследовательский институт, Почвенный институт имени В. В. Докучаева, Сибирский государственный университет геосистем и технологий, Гидрометеорологический научно-исследовательский центр РФ, Институт вычислительных технологий СО РАН, Белгородский государственный национальный исследовательский университет, Московский государственный университет имени М. В. Ломоносова. Значительный вклад в разработку методов ДЗЗ и использования спутниковых данных в мониторинге растительных покровов внесли ученые: Алтынцев М. А., Баргалева С. А., Беленко В. В., Братков В. В., Гук А. П., Лупян Е. А., Малинников В. А., Савин И. Ю., Терехов А. Г., Чернов А. В., Якушев В. П., Huete A. R., Mandal D., McNairn H., Rouse J. W., Sakamoto T.

Цель и задачи исследования. Цель исследования заключается в разработке методики мониторинга пахотных земель с применением дешифрирования данных

ДЗЗ, которая позволяет восстанавливать сведения и контролировать соблюдение севооборотов, а также оперативно прогнозировать урожайность.

Для достижения поставленной цели требовалось решить следующие задачи:

– выполнить аналитический обзор современных технологий получения, обработки и использования данных ДЗЗ для решения задач сельскохозяйственного мониторинга;

– разработать алгоритм автоматизированного распознавания посевов с оценкой точности для основных сельскохозяйственных культур Дальнего Востока с использованием как оптических, так и радиолокационных данных;

– создать алгоритм раннего распознавания посевов сельскохозяйственных культур на основе мультиспектральных данных и методов машинного обучения;

– разработать принципы построения моделей для раннего прогнозирования урожайности сельскохозяйственных культур (на примере сои) с использованием спутниковых и метеорологических данных и оценить точность полученных моделей.

Объект и предмет исследования. Объектом исследования выступают снимки, полученные в результате спутниковой съёмки сельскохозяйственных угодий. *Предметом* исследования является методика сельскохозяйственного мониторинга на основе машинного обучения и данных ДЗЗ.

Научная новизна диссертационного исследования заключается в следующем: разработан способ построения непрерывных временных рядов композитов NDVI посредством аппроксимации с использованием ряда Фурье для проведения многолетних исследований пахотных земель на обширной территории; впервые для Дальнего Востока построены «эталонные» кривые сезонного хода оптических и радиолокационных вегетационных индексов для основных сельскохозяйственных культур; разработан алгоритм раннего распознавания посевов основных сельскохозяйственных культур Дальнего Востока с использованием многолетних данных ДЗЗ и методов машинного обучения, позволяющий повысить оперативность построения карт пахотных земель; разработаны принципы построения моделей для раннего прогнозирования урожайности на районном уровне с использованием

спутниковых и метеорологических данных, способствующие получению заблаговременного прогноза с низкой ошибкой.

Теоретическая и практическая значимость работы.

Теоретическая значимость исследования заключается в разработке подходов к использованию многолетних данных ДЗЗ для распознавания основных сельскохозяйственных культур Дальнего Востока в течение сельскохозяйственного сезона. Также предложены принципы построения регрессионных моделей для раннего прогнозирования урожайности с использованием значений NDVI и климатических характеристик.

Практическая значимость работы состоит в том, что разработанная методика может использоваться для автоматизированного создания масок сельскохозяйственных культур, выявления неиспользуемой пашни уже в середине сельскохозяйственного сезона, а также с высокой точностью оценивать урожайность сельхозкультур на уровне муниципальных районов. Разработанные модели на основе машинного обучения позволят оперативно строить карты пахотных земель, а также оценивать площади посевов сельскохозяйственных культур и неиспользуемой пашни на муниципальном и региональном уровне. Также автоматизированное распознавание посевов сельскохозяйственных культур может быть использовано для восстановления сведений о севообороте в предыдущие сельскохозяйственные сезоны.

Методология и методы исследования. В качестве методологической основы использованы методы обработки спутниковых изображений для получения значений вегетационных индексов, регрессионного анализа, машинного обучения. Эмпирической основой исследований служили снимки, полученные с космических аппаратов Terra, Sentinel-2A/B и Sentinel-1B (2010–2023 гг.), средние значения урожайности сои в районах Дальнего Востока (за период с 2010 по 2019 г.), данные наземных наблюдений о севообороте на полях сельскохозяйственных предприятий Хабаровского района, маски пахотных земель и метеорологические данные, полученные из сервиса Vega-Science.

Положения, выносимые на защиту:

– на основе аппроксимированных временных рядов индексов вегетации и методов машинного обучения разработан алгоритм распознавания посевов основных сельскохозяйственных культур Дальнего Востока. Разработанный алгоритм позволяет восстанавливать сведения о севообороте пахотных земель, осуществлять картографирование в ретроспективном периоде, уточнять границы полей, выявлять неиспользуемые земли (соответствует п. 10, 12 паспорта научной специальности);

– предложен алгоритм раннего распознавания посевов сельскохозяйственных культур Дальнего Востока с использованием сокращенных аппроксимированных временных рядов индекса NDVI и машинного обучения. Разработанный алгоритм способствует оперативному построению карт пахотных земель, позволяет контролировать соблюдение севооборотов и корректировать посевную стратегию (соответствует п. 10, 12 паспорта научной специальности);

– сформулированы принципы, построены и апробированы модели раннего прогнозирования урожайности на районном уровне, основанные на предварительном расчете максимума временных рядов NDVI с использованием параметров аппроксимирующих функций. Предложенные модели обеспечивают возможность оперативной оценки урожайности в ходе вегетационного сезона с точностью свыше 90 % для планирования валового сбора сельхозкультур (соответствует п. 10 паспорта научной специальности).

Соответствие диссертации паспорту научной специальности. Диссертация соответствует областям исследования: 10 – Развитие и применение методов обработки и анализа больших данных, формируемых средствами ДЗЗ, в том числе с применением машинного обучения и искусственного интеллекта, для решения задач геофизики, геодинамики, климатологии, океанологии и др. наук о Земле; 12 – Теория и методы автоматизации фотограмметрических измерений и дешифрирования изображений, в том числе на основе систем искусственного интеллекта, с целью картографирования и формирования ГИС различной тематической направленности паспорта научной специальности 1.6.19. Аэрокосмические исследования Земли, фотограмметрия, разработанного экспертным советом ВАК Минобрнауки России.

Степень достоверности и апробация результатов исследования. Результаты выполненных исследований представлены: на Международной научно-практической конференции «Научное обеспечение устойчивого развития агропромышленного комплекса» (16–17 июля 2020 г., Хабаровск); I и III Международных конференциях по цифровизации сельского хозяйства и органическому производству (7–9 июня 2021 г., Санкт-Петербург; 5–7 июня 2023 г., Санкт-Петербург); VI и VII Международных научно-практических конференциях «Информационные технологии и высокопроизводительные вычисления» (14–16 сентября 2021 г., Хабаровск; 11–13 сентября 2023 г., Хабаровск); III Всероссийской научной конференции с международным участием «Применение средств дистанционного зондирования Земли в сельском хозяйстве» (16–17 сентября 2021 г., Санкт-Петербург); XIX, XX, XXI и XXII Международных конференциях «Современные проблемы дистанционного зондирования Земли из космоса» (15–19 ноября 2021 г., Москва; 14–18 ноября 2022 г., Москва; 13–17 ноября 2023 г., Москва; 11–15 ноября 2024 г., Москва); Международной научной конференции «Агрофизический институт: 90 лет на службе земледелия и растениеводства» (14–15 апреля 2022 г., Санкт-Петербург); IX Международной научной конференции «Региональные проблемы дистанционного зондирования Земли» (13–16 сентября 2022 г., Красноярск); Международной научно-практической конференции «Современные проблемы, тенденции и перспективы научно-инновационного обеспечения агропромышленного комплекса» (18–19 апреля 2023 г., Благовещенск); Национальной научно-практической конференции «Чтения памяти доктора сельскохозяйственных наук, профессора Александра Петровича Ващенко» (20 марта 2024 г., Уссурийск); XX Международной выставке и научном конгрессе «Интерэкспо ГЕО-Сибирь-2024» (15–17 мая 2024 г., Новосибирск).

Разработанная методика применяется в Хабаровском Федеральном исследовательском центре ДВО РАН для картографирования пахотных земель и прогнозирования урожайности сои в районах Дальнего Востока.

Публикации по теме диссертации. Основные результаты представлены в 26 научных работах, 3 из которых опубликованы в изданиях, входящих в пере-

чень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени кандидата наук; 7 статей входят в международные реферативные базы данных Scopus и Web of Science. Получено 3 свидетельства о государственной регистрации программы на ЭВМ и 1 свидетельство о государственной регистрации базы данных.

Структура диссертации. Общий объем составляет 148 страниц машинописного текста. Диссертация состоит из введения, четырех разделов, заключения, списка литературы, включающего 163 наименования, содержит 17 таблиц, 52 рисунка, 2 приложения.

1 ПРИМЕНЕНИЕ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ ДЛЯ РЕШЕНИЯ ЗАДАЧ МОНИТОРИНГА ПАХОТНЫХ ЗЕМЕЛЬ

1.1 Задачи мониторинга сельскохозяйственных земель

Мониторинг сельскохозяйственных земель – система оперативных, периодических и базовых наблюдений за изменением качественного и количественного состояния земель сельскохозяйственного назначения и земель, используемых или предоставленных для ведения сельского хозяйства в составе земель иных категорий, как природного и производственного объекта для ведения сельского хозяйства, их хозяйственным использованием, и обследований этих земель, почв и их растительного покрова, проводимых с определенной периодичностью [20]. Он включает в себя систематические наблюдения за состоянием и использованием полей, уточнение их контуров; за изменением состояния растительного покрова на пашне, залежах, сенокосных и пастбищных угодьях (изменение видового состава, тип и качество растительности, степень устойчивости к антропогенным нагрузкам).

Точное картографирование пахотных земель может дать важнейшую информацию для оценки площади сельскохозяйственных посевов. Актуальность решения этой задачи напрямую связана как с необходимостью уточнения севооборота на отдельных полях, так и в целом с оценкой использования пахотных земель [21]. В то же время ежегодное уточнение данных наземных наблюдений является очень трудоемкой и дорогостоящей процедурой. Для Дальнего Востока она представляется особенно сложной из-за большой площади территории и неразвитой транспортной инфраструктуры [17]. Ситуация усугубляется существованием большого количества заброшенных сельскохозяйственных земель, наличие которых слабо отражено в официальной статистике. Получение качественных карт пахотных земель позволяет повысить точность прогнозирования урожайности сельскохозяйственных культур.

Урожайность сельскохозяйственных культур – один из важнейших показателей эффективности всего агропромышленного комплекса, учитываемый при пла-

нировании импортно-экспортных операций на рынке сельскохозяйственной продукции. Стандартные методы сбора информации об урожайности на уровне страны и ее административных единиц часто субъективны [30].

Мониторинг состояния посевов сельскохозяйственных культур подразумевает проведение периодических наблюдений, оценку текущего состояния, а также прогнозирование дальнейшего развития посевов [44, 41, 64]. Использование данных дистанционного зондирования Земли (ДЗЗ) позволяет улучшить качество карт пахотных земель, повысить точность прогнозирования урожайности сельскохозяйственных культур, снизить затраты на проведение наземных исследований.

1.2 Современные спутниковые системы и получение данных для сельскохозяйственного мониторинга

1.2.1 Спутниковые аппараты

Для исследования растительного покрова используются космические снимки различного пространственного и временного разрешения [7, 14].

Примерами спутниковых систем с низким пространственным разрешением (более 100 м) могут выступать спутники Terra и Aqua, входящие в группировку спутников ДЗЗ программы Earth Observing System (EOS) Национального управления по воздухоплаванию и исследованию космического пространства (National Aeronautics and Space Administration, NASA, США) [132]. Для мониторинга растительного покрова особый интерес представляют данные сенсора MODIS, установленного на обоих аппаратах. Ширина полосы захвата на местности составляет 2 300 км, а значение пространственного разрешения варьируется от 250 м до 1 км [131]. Наличие необходимых спектральных каналов, глобальный охват, ежедневная периодичность и наличие большого объема накопленных данных выгодно отличают прибор MODIS среди приборов низкого пространственного разрешения для решения задач сельскохозяйственного мониторинга [11, 26, 65].

Примерами спутниковых группировок, при помощи которых можно получать данные среднего пространственного разрешения (10–100 м), являются группиров-

ки Landsat и Sentinel. Миссия Landsat, курируемая NASA, имеет долгую историю: первый спутник был запущен ещё в 1972 г. [155]. В настоящее время для решения задач мониторинга используются данные со спутников Landsat-8 и Landsat-9. Оба спутника имеют схожее оборудование на борту (оптико-электронный сенсор Operational Land Imager (OLI) и тепловой сенсор Thermal Infrared Sensor (TIRS)), что позволяет использовать информацию с обоих спутников совместно без дополнительной обработки/калибровки. Использование двух спутников позволяет получать снимки с периодичностью 8 дней. Сенсоры OLI получают изображения в 9 диапазонах видимой области спектра и ближней инфракрасной зоне излучения [33] с пространственным разрешением 30 м. Данные сенсоров OLI широко применяются для мониторинга растительных покровов (в том числе пахотных земель) [6, 13, 23].

Обеспечение спутниковыми данными программы глобального мониторинга окружающей среды Copernicus, разработанной в 1998 г. Еврокомиссией и Европейским космическим агентством (ESA), возложено на группировку спутников Sentinel [84]. Группировка спутников Sentinel предоставляет как оптико-электронные, так и данные радиолокации [33].

Группировка Sentinel-1 до 2022 г. состояла из двух спутников на полярной орбите, оснащенных радаром для съемок в С-диапазоне. Спутник Sentinel-1A выведен на орбиту 3 апреля 2014 г., спутник Sentinel-1B был запущен 25 апреля 2016 г. В августе 2022 г. спутник Sentinel-1B был выведен из эксплуатации. Съемка производится в С-диапазоне с помощью радара с синтезированной апертурой Synthetic Aperture Radar (SAR) и не зависит от времени суток и облачности [15]. Данные Sentinel-1 используются для мониторинга природных процессов, в том числе и в задачах сельского хозяйства [51, 61].

Группировка Sentinel-2 состоит из двух спутников. Период повторной съемки в зависимости от широты варьируется от пяти до двух-трех дней [96]. Спутники Sentinel-2 оснащены оптико-электронным мультиспектральным сенсором Multispectral Instrument (MSI) для съемок с разрешением 10 (видимая часть спектра, ближний инфракрасный), 20 (Red Edge и коротковолновые инфракрасные диапа-

зоны) и 60 м (водный пар, аэрозоль). Наличие 13 спектральных каналов позволяет выявлять изменения в развитии растений, а также снижает влияние атмосферы на качество съемки. Уникальность миссии Sentinel-2 связана с сочетанием большого территориального охвата, высокой частоты съемки, и, как следствие, систематическим получением полного покрытия всей Земли мультиспектральной съемкой [33]. Поэтому данные Sentinel-2 получили наиболее широкое распространение в современных исследованиях по мониторингу растительных покровов [25, 60], в том и числе и в сельскохозяйственном мониторинге: составлении карт пахотных земель [27, 59] и прогнозировании урожайности [38, 35].

К спутниковым системам с высоким пространственным разрешением относятся спутники Канопус-В, входящие в российскую орбитальную группировку спутников. Серия спутников Канопус-В, разработанная АО Корпорация ВНИИЭМ, в настоящий момент представлена пятью аппаратами: Канопус-В № 3, № 4 (запущены 1 февраля 2018 г.), № 5, № 6 (запущены 27 декабря 2018 г.) и Канопус-В-ИК (запущен 14 июля 2017 г.) [28]. Группировка Канопус-В выполняет съемку поверхности Земли в панхроматическом режиме с разрешением 2,5 м и мультиспектральном режиме (синий, зелёный, красный, ближний инфракрасный диапазоны съемки) с разрешением 12,5 м. Информация, получаемая с этих спутников, используется различными ведомствами РФ, в том числе для решения задач сельскохозяйственного мониторинга, землепользования и картографии [8, 63].

1.2.2 Вегетационные индексы

Основываясь на комбинировании функций яркостных значений объектов на снимках, полученных в определенных спектральных каналах, можно рассчитать индексные значения каждого пикселя исследуемой области, которые необходимы для проведения анализа и оценки исследуемого объекта по его изображениям на снимке. Спектральные индексы, используемые для оценки состояния растительности, называются вегетационными индексами [33]. Более густая и здоровая растительность характеризуется большей разностью отражения света в красном и ближнем инфракрасном диапазоне спектра. Поэтому большая часть вегетацион-

ных индексов, получаемых по оптическим данным, рассчитывается именно по значениям в этих каналах [8, 32, 59].

Самым используемым в научных исследованиях вегетационным индексом является нормализованный разностный вегетационный индекс растительности (NDVI) [122], который рассчитывается по формуле:

$$NDVI = \frac{NIR-RED}{NIR+RED}, \quad (1.1)$$

где NIR – интенсивность отражения света в ближнем инфракрасном диапазоне;

RED – интенсивность отражения света в видимом красном диапазоне.

NDVI может принимать значения от -1 до 1 , но для растительности свойственны значения от 0 до 1 . Низкие значения NDVI характерны для периодов после вспашки (голая почва), в начале вегетационного цикла сельскохозяйственных культур, а также после уборки урожая. Пониженный NDVI в середине периода вегетации сельскохозяйственной культуры указывает на плохое состояние растений (недостаток влаги, болезни).

Улучшенный вегетационный индекс (EVI) также использует отражательную способность поверхности в синей области спектра [134]:

$$EVI = 2 \left(\frac{NIR-RED}{NIR+6 \cdot RED-7,5 \cdot BLUE+1} \right), \quad (1.2)$$

где $BLUE$ – интенсивность отражения в синей области спектра.

Синий канал используется для коррекции фоновых сигналов почвы и аэрозольного рассеяния. EVI показывает свою эффективность в случае густой растительности, когда NDVI может перенасыщаться. Для растительного покрова значения EVI обычно лежат в диапазоне от 0 до 1 .

Почвенный вегетационный индекс (SAVI) – вегетационный индекс, учитывающий влияние различных видов почв, который рекомендован к применению при разреженной растительности [107]. Индекс SAVI является модификацией NDVI, учитывающей влияние подстилающей поверхности при помощи корректирующего фактора L (чаще всего используется значение $0,5$):

$$SAVI = \frac{NIR-RED}{NIR+RED+L} \cdot (1 + L). \quad (1.3)$$

Данные радиолокации, не зависящие от освещения и погодных условий, являются надежной альтернативой для долгосрочного мониторинга севооборота. Радиолокационный индекс растительности (RVI) является наиболее распространенным радиолокационным вегетационным индексом [117]:

$$RVI = \frac{8\gamma_{HV}^0}{\gamma_{HH}^0 + \gamma_{VV}^0 + 2\gamma_{HV}^0}, \quad (1.4)$$

где γ_{HH}^0 – эффективная площадь рассеяния для поляризации HH;

γ_{HV}^0 – эффективная площадь рассеяния для поляризации HV;

γ_{VH}^0 – эффективная площадь рассеяния для поляризации VH;

γ_{VV}^0 – эффективная площадь рассеяния для поляризации VV.

Этот индекс чувствителен к динамике вегетации растений, поэтому его можно использовать для оценки состояния сельскохозяйственных культур [109, 112].

В отличие от RVI, в основе получения радиолокационного вегетационного индекса с двойной поляризацией (DpRVI) лежат преобразования комплексных поляриметрических радиолокационных данных уровня обработки Level-1 SLC (Single Look Complex) [89]. DpRVI рассчитывается по формуле:

$$DpRVI = 1 - m\beta, \quad (1.5)$$

где m – степень поляризации – отношение средней интенсивности поляризованной части волны к средней общей интенсивности волны ($0 \leq m \leq 1$);

β – мера доминирующего механизма рассеяния, которая определяется из спектрального разложения матрицы на два неотрицательных собственных значения ($\lambda_1 \geq \lambda_2 \geq 0$).

Обработка выполняется одним из методов поляриметрической декомпозиции. Благодаря таким расчетным показателям, как степень поляризации и мера доминирующего механизма рассеяния, индекс DpRVI становится более чувствительным к росту культур и применяется как относительно простой и физически интерпретируемый дескриптор растительности [21].

1.3 Анализ существующих методов использования данных дистанционного зондирования Земли для решения задач сельского хозяйства

1.3.1 Идентификация посевов сельскохозяйственных культур и составление карт пахотных земель

Методы точного земледелия позволяют получать точную количественную оценку площадей, занимаемых посевами сельскохозяйственных культур, уточнять расположение и границы полей.

В мире существует успешный опыт создания масштабных карт пахотных земель [17]. Например, в Департаменте сельского хозяйства США ещё в 2008 г. была создана карта пахотных земель с выделенными на ней отдельными культурами Cropland Data Layer (CDL) [128]. Этот продукт охватывает все континентальные штаты США, имеет пространственное разрешение 30 м. Заявленная точность для основных культур в ведущих сельскохозяйственных штатах составляет приблизительно 95 %. В Евросоюзе была разработана система идентификации сельскохозяйственных полей (LPIS). LPIS – это геоинформационная система, обеспечивающая определение местоположения и физические измерения земельных участков, а также ведение уникального набора идентификаторов для земельных участков. В LPIS регистрируются сельскохозяйственные поля, используемые под сев культур площади, и создается основа для оценки рисков, связанных с кредитованием в сельском хозяйстве [145].

Для формирования таких карт используются как данные, собранные в результате наземных наблюдений, так и полученные методами автоматизированного распознавания пахотных земель и посевов сельскохозяйственных культур. Наличие таких национальных и наднациональных карт позволяет исследователям осуществлять обучение и валидацию собственных моделей, построенных с использованием методов машинного обучения [67, 162]. Так, например, в работе группы учёных из Германии [125] сведения из LPIS использовались для обучения и валидации модели, основанной на использовании оптических (Sentinel-2, Landsat-8) и радиолокационных (Sentinel-1) данных и метода Random Forest (RF)

при картографировании посевов основных сельскохозяйственных культур на всей территории Германии. В статье корейских исследователей [160] при картографировании пахотных земель на двух тестовых площадках в США использовались снимки Google Street View и сверточные нейронные сети, при этом для валидации результатов использовались данные CDL.

С развитием космической отрасли, методов искусственного интеллекта и повышением доступности спутниковых данных стало возможно создавать глобальные карты пахотных земель на основе данных ДЗЗ. Такими крупными глобальными проектами стали всемирная карта пахотных земель (Map of Worldwide Croplands), разработанная геологической службой США (USGS) в рамках проекта GFSAD [120], и WorldCover от Европейского спутникового агентства [159]. На карте, созданной USGS, показано распределение пахотных земель по всему миру с разрешением 30 м на основе снимков Landsat за 2015 г. Для построения карты использовались алгоритмы машинного обучения на платформе облачных вычислений Google Earth Engine. Последняя версия продукта WorldCover создана в 2021 г. и содержит 11 классов земной поверхности (в том числе пахотные земли). Для классификации использовались оптические данные, полученные со спутников Sentinel-2, и данные радиолокации, полученные со спутников Sentinel-1.

Однако точность глобальных карт пахотных земель сравнительно невысока (так, например, для продукта WorldCover общая точность составляет 77 % [97]) и сильно варьируется в различных регионах. К тому же эти карты могут использоваться для создания маски пахотных земель, но не отдельных культур. В ряде работ показаны неточности при определении границ полей и сведений о севообороте в национальных картах пахотных земель, основанных на данных официальной статистики, что затрудняет их использование на региональном уровне [118, 153].

В России функционирует единая федеральная система о землях сельскохозяйственного назначения (ЕФИС ЗСН), аккумулирующая информацию о севообороте на сельскохозяйственных полях муниципальных образований Российской Федерации [19]. Основными задачами, для решения которых создавалась ЕФИС ЗСН, являются получение, хранение, обработка сведений об использовании зе-

мель сельскохозяйственного назначения Российской Федерации. Одной из составных частей ЕФИС ЗСН является специализированный блок работы с данными ДЗЗ, получивший название «Аналитик ДЗЗ ЕФИС ЗСН» [10, 22]. Блок разработан на базе сервисов спутникового мониторинга растительности семейства ВЕГА [52]. Основной задачей блока является оперативное получение объективной информации о состоянии и использовании сельскохозяйственных земель, а также верификация данных, предоставляемых подведомственными Минсельхозу России учреждениями. В блоке ДЗЗ ЕФИС ЗСН реализован широкий набор различных инструментов, способствующих проведению мониторинга земель сельскохозяйственного назначения [10]. Его создание направлено на автоматизированное выявление неиспользуемых сельскохозяйственных земель, верификацию и коррекцию сведений о севообороте, мониторинг состояния посевов на основе данных дистанционного зондирования Земли. К сожалению, полнота и качество предоставляемой ЕФИС ЗСН информации значительно варьируются. В некоторых регионах проведена полная оцифровка полей (уточнены границы полигонов, внесены и верифицированы сведения о сельскохозяйственных культурах). В других регионах информация о севообороте за некоторые годы отсутствует, а границы сельскохозяйственных полей давно не актуализировались. Так, например, в ЕФИС ЗСН полностью отсутствуют данные о культурах, произраставших на полях Хабаровского края в 2021 и 2022 гг., а данные о севообороте за 2018–2020 гг. содержат значительное количество неточностей [17]. Создание в 2023 г. цифровой карты сельскохозяйственных земель позволило внести в ЕФИС информацию о севообороте за 2023 г., но при этом границы полей не совпадают с реальными. Другой проблемой является то, что методы создания масок сельскохозяйственных культур, разработанные в ИКИ РАН [31], создавались преимущественно для муниципальных образований европейской части РФ. Отличные от регионов других федеральных округов сортовой состав, сроки сева и уборки урожая затрудняют использование существующих критериев распознавания посевов сельскохозяйственных культур для регионов Дальнего Востока [17].

Поэтому, в настоящее время большое внимание уделяется использованию методов машинного обучения для создания точных региональных масок пахотных земель и отдельных культур по спутниковым данным [69, 122].

Самым простым методом построения масок сельскохозяйственных культур является использование каналов мультиспектральных изображений. Например, в статье группы китайских учёных для выявления посевов двух культур (пшеницы и рапса), а также залежных земель использовался один безоблачный гиперспектральный снимок китайского спутника OHS-2A с пространственным разрешением 10 м [88]. Две тестовые площадки исследования находились в провинции Хубей в Китае. Для классификации использовалась шестислойная сверточная нейронная сеть, обучающаяся на значениях всех 32 каналов спутникового прибора. Точность классификации для обеих площадок оказалась выше 92 %. Однако использование спутникового продукта со всеми его каналами требует значительных временных затрат при обучении. Также возникает вопрос избыточности данных.

Чаще всего проблема классификации пахотных земель решается путем использования значений видимого и инфракрасного диапазонов спектра в качестве исходных данных [24]. При этом используются не сами значения каналов, а специализированные вегетационные индексы, являющиеся их комбинациями (NDVI, EVI и т. д.).

В работе международной группы учёных приведены результаты экспериментальных исследований по автоматизированному дешифрированию видовой структуры сельскохозяйственных культур (ржи озимой, пшеницы озимой, пшеницы яровой, тритикале озимого, рапса озимого, ячменя, овса, гречихи, кукурузы, многолетних трав и зернобобовых культур) на основе снимков Landsat-8 [103]. Исследуется возможность применения различных характеристик (в том числе NDVI) в разные периоды вегетационного цикла (май, июль, август). Точность картографирования по NDVI оказалась низкой – максимальная общая точность достигнута для снимка, сделанного в мае (64,9 %), точность распознавания отдельных культур варьировалась от 31,5 % для озимой ржи до 93 % для многолетних трав.

Значительная вариация точности распознавания различных культур в различные даты съёмки связана с различными датами сева и уборки, темпами роста сельскохозяйственных культур и т. д. Более комплексным подходом для анализа динамики растительных покровов является использование сезонных временных рядов индексов вегетации, учитывающих особенности роста культур [128]. Поэтому временные ряды получили широкое распространение при картографировании пахотных земель с применением различных методов машинного обучения, ориентированных на работу с входными последовательностями. Группа учёных из университета Исфахана (Иран), используя значения NDVI, вычисленные по данным пяти спутниковых снимков Landsat-8 в течение периода вегетации (март-октябрь), построила карту пахотных земель для местности, характеризующейся малым размером сельскохозяйственных полей и большим разнообразием сельскохозяйственных культур [76]. При этом для классификации разработана гибридная схема: для определения посевов зерновых культур и фруктовых деревьев использовались деревья решений, построенные на основе логических правил, основанных на вариации значений NDVI, а для выделения посевов риса и овощных культур использовался метод опорных векторов (SVM). Точность классификации в обоих случаях была выше 90 %.

В одном из исследований, проводившихся в Марокко, для картографирования пахотных земель применялись временные ряды NDVI, полученные по приведенным к пространственному разрешению 15 м снимкам Landsat-8 (10 изображений за сезон) [85]. Для обучения и валидации размечены 1 080 сельскохозяйственных полей в Марокко. Ряды NDVI разделены на группы (свекла, пшеница, ячмень и люцерна), из каждой группы удалены ряды, значительно отклоняющиеся от усредненных рядов по культуре. Для классификации выбраны методы RF, SVM и Spectre Angle Mapper (SAM). Максимальная точность для алгоритма RF составила 89 %. При этом стоит отметить, что посевы сахарной свеклы и зерновых культур определены с точностью выше 90 %, а для посевов люцерны точность оказалась несколько ниже (около 80 %). Научная группа из Китая [86] использовала временные ряды NDVI, полученные по данным спутниковой группировки

ровки Sentinel-2 для картографирования посевов сельскохозяйственных культур на севере Китая. В этом масштабном исследовании использовались 394 характеристики (включая вычисленные с использованием значений NDVI). В ходе анализа выявлены 20 наиболее информативных признаков, участвующие в классификации. В качестве методов машинного обучения выступали RF, SVM и нейронная сеть. Наилучшие результаты (общая точность составила 93 %) достигнуты при использовании метода RF.

Существенным недостатком оптических данных является значительное влияние атмосферных явлений, таких как различные типы облаков, дымка, аэрозоли и тени от облаков, на значения коэффициентов спектральной яркости, а следовательно, и производных вегетационных индексов [46]. Экспертное или автоматизированное удаление облачности на снимках является непростой задачей и часто может приводить к значительной разреженности временных рядов. Процесс вычисления временных композитов вегетационных индексов помогает минимизировать негативное влияние атмосферных явлений, а также сокращает объем исходных данных.

В ИКИ РАН были разработаны автоматические методы для распознавания посевов озимых культур на основе временных серий четырёхдневных композитов спутниковых данных спектрорадиометра MODIS. Это позволило сформировать серию ежегодных карт озимых на всю территорию их регулярного возделывания в РФ с пространственным разрешением 250 м [37]. При выявлении посевов озимых культур рассматривалось множество разновременных композитных изображений перпендикулярного вегетационного индекса (PVI) методом RF. В среде программного комплекса LAGMA-PLUS на основе метода LAGMA [70] проводилось автоматизированное разделение пахотных земель на два класса, соответствующих озимым и прочим сельскохозяйственным культурам. Для обучения использовались данные наземных обследований 3 067 сельскохозяйственных полей, включающие информацию о севообороте (более 20 культур или групп культур) за пять лет (2012–2016 гг.), корректность границ полей была оценена визуально на основе данных Landsat-8 и Sentinel-2. Общая точность классификации озимых

культур варьировала в диапазоне значений от 70 до 98 %, демонстрируя зависимость от субъекта РФ и указывая на региональные ограничения применимости получаемых карт [37].

Распространенным подходом является распознавание посевов на основе анализа 16-дневных композитных изображений MODIS NDVI [110, 139]. Примером использования такого подхода является классификация севооборотов в провинции Токантин (Бразилия) [110]. Для уточнения границ полей дополнительно производился анализ снимков Landsat-8. Обучение без учителя проводилось методом *k* средних с разбиением на 10 классов. В качестве классов выступали типы севооборотов. При этом вся территория дополнительно разбивалась на 120 кластеров по типам ландшафтов. Для валидации использовались данные наземного наблюдения (900 точек в 35 муниципалитетах). Общая точность определения севооборотов при локализации на основе пространственных кластеров составила 93 %.

Необходимо отметить, что применение продуктов MODIS с пространственным разрешением 250 м не позволяет точно определять границы сельскохозяйственных полей (в упомянутых работах для этого анализировались снимки с более высоким пространственным разрешением), а также идентифицировать посеvy сельскохозяйственных культур для небольших участков или полей, на которых одновременно произрастает сразу несколько культур. Доказательством этого утверждения являются результаты исследования, проведенного в ИКИ РАН. В нём изучалось влияние пространственного разрешения данных дистанционного зондирования Земли на средние значения вегетационного индекса NDVI в границах сельскохозяйственных полей в зависимости от их площади. Использовались три набора данных, полученных на основе информации с приборов MODIS, Комплекса многозональной спутниковой съёмки (KMCC) и MultiSpectral Instrument (MSI) с пространственным разрешением 250, 60 и 10 м/пиксель соответственно [2]. Сделан вывод о том, что для полей площадью более 10–15 га ход среднего индекса NDVI имеет схожие тренды по данным с различным пространственным разрешением. Для полей меньшего размера присутствуют большие различия в период наимень-

ших значений индекса NDVI, что затрудняет использование данных MODIS и КМСС для мониторинга сельскохозяйственных культур на малых полях.

В большей части исследований для создания композитов используются снимки спутниковых систем Landsat, либо Sentinel. Например, в статье [94] производилось распознавание посевов сельскохозяйственных культур на полях в Узбекистане с использованием месячных композитов NDVI, EVI и нормализованного разностного водного индекса (NDWI) по данным спутников Landsat-8 и Sentinel-2 (раздельно) за период вегетации в 2018 г. В качестве классов выступали хлопок, пшеница, рис и другие культуры. В качестве методов машинного обучения использовались RF и SVM. Максимальная точность для тестовых полигонов достигнута при одновременном использовании композитов EVI и NDVI, полученных со спутника Landsat-8, в сочетании с методом RF – 92 %.

Нередки случаи совместного использования данных обеих этих группировок для создания композитов. Для автоматизированной классификации сельскохозяйственных земель Германии (более 1 000 000 полей) использовались изображения Landsat-8 (30 м) и Sentinel-2 (10 м), приведённые к разрешению 30 м [104]. По этим спутниковым данным вычислялись 10-дневные композиты за сельскохозяйственный сезон 2016–2017 гг. (всего 45 композитов). В качестве метода классификации использовался RF. Всего идентифицировались посевы восьми сельскохозяйственных культур. Точность классификации варьировалась от 70 % для яровых зерновых до 97 % для рапса. Основной сложностью при работе с данными, полученными с разных сенсоров, является необходимость выполнять процедуру корегистрации из-за отличающихся траекторий движения спутниковых аппаратов и пространственного разрешения снимков. Также аналогичные каналы для различных приборов имеют несколько отличающиеся диапазоны частот, что может приводить к разным значениям вегетационных индексов в одинаковых условиях.

Часто в регионах, для которых характерны ярко выраженные сезоны дождей, длительные периоды облачности, наличие аэрозолей или тумана в течение вегетационного сезона, между датами получения оптических изображений, пригодных для решения задач растительного покрова, могут проходить достаточно

большие промежутки времени. Если такой промежуток длится две недели и более, расчет композитов (даже 16-дневных) недостаточен для получения непрерывных временных рядов. На практике проблема разреженности временных рядов встречается очень часто. В таких случаях недостающие значения восстанавливаются с помощью интерполяции, используя соседние известные значения [116], сплайны [68] либо фильтры [83, 150].

Более комплексным подходом к восстановлению целостности временных рядов является аппроксимация. В этом случае выбирается аппроксимирующая функция, форма которой похожа на сезонный ход вегетационного индекса. Существует целый ряд исследований по выбору функций для аппроксимации наиболее популярных вегетационных индексов. Например, для аппроксимации временных рядов NDVI использовались полиномы [105], функция Гаусса [115], логистические функции [139, 161], ряд Фурье [113, 144, 158] и метод гармонического анализа временных рядов (HANTS) [163]. В исследовании, проводившемся на территории Индии, для моделирования сезонных вариаций вегетационных индексов применялись четыре метода: фильтр Уиттакера, а также аппроксимация рядом Фурье, функцией Гаусса и двойной логистической функцией [113]. Использование аппроксимации позволило достигнуть высокой точности моделирования в регионах, где выращиваются исключительно яровые культуры. Учёные из Самарского национального исследовательского университета имени академика С. П. Королёва произвели аппроксимацию сезонного хода NDVI с использованием кусочно-линейной, асимметричной гауссовой и двойной логистической функций, ряда Фурье и полиномов для сельскохозяйственных полей в Самарской области [158]. Наименьшая ошибка при аппроксимации временных рядов парующих земель наблюдалась при использовании ряда Фурье. Использование методов восстановления временных рядов активно используется и при картографировании пахотных земель. Так, в работе американских учёных [144] для восстановления временных рядов в целях повышения точности классификации использовались фильтры Савицкого – Голэя и Уиттакера, а также аппроксимация рядом Фурье, функцией Гаусса и двойной логистической функцией. Наибольшая точность клас-

сификации достигнута при использовании ряда Фурье (точность классификации повысилась на 6 % по сравнению с использованием фильтров).

Для создания качественного классификатора необходимо учитывать межгодовую изменчивость временных рядов, связанную с климатическими, гидрологическими условиями и антропогенными факторами. Поэтому исследования с использованием многолетних спутниковых данных с практической точки зрения видятся более перспективными. А использование композитов и методов восстановления временных рядов вегетационных индексов позволяет унифицировать длину временных рядов. Для определения севооборотов (всего 14 классов) в пяти сельскохозяйственных муниципалитетах в Мьянме использовались 8-дневные композиты NDVI и EVI, полученные по данным MODIS [100]. Для классификации использовались алгоритмы SVM, RF и C5.0. Максимальная точность классификации (95 %) достигнута при использовании метода RF и 8-дневных композитов NDVI за три года исследования в качестве входных данных.

Практически важной задачей сельского хозяйства является идентификация посевов сельскохозяйственных культур в текущем сезоне на основе размеченных карт предыдущих лет, а также восстановление отсутствующих сведений о севообороте в предыдущие годы. Например, американские учёные использовали 8-дневные композиты MODIS NDVI за 2008–2014 гг. для создания карт пахотных земель в США на 2015–2018 гг [124]. Средняя многолетняя точность классификации для основных культур (кукуруза, соя, пшеница) превысила 90 %. В исследовании группы учёных из Китая [74] временные ряды значений отдельных каналов (видимого и инфракрасного спектра) и вегетационных индексов (NDVI, EVI, NDWI и т. д.) за вегетационный период (с апреля по октябрь) 2020 г., построенные по данным Sentinel-2, использовались для восстановления сведений о севообороте для сельскохозяйственного региона Хэтао (Китай) в 2019 г. Общая точность картографирования в 2019 г. превысила 90 %, значение метрики F1 варьировалось от 0,8 для пшеницы до 0,92 для подсолнечника (также проводилось распознавание посевов кукурузы и цукини).

Альтернативой оптическим данным при составлении карт пахотных земель могут являться данные радаров с синтетической апертурой (SAR). Устойчивость данных радиолокации к атмосферным явлениям позволяет получать непрерывные временные ряды с достаточно большим количеством наблюдений за сезон. Поэтому данные радиолокации в последнее время применяются при картографировании посевов сельскохозяйственных культур и выявлении заброшенных пахотных земель. В большинстве исследований анализируются поляризации VV и VH, либо их соотношение (VH/VV). Например, по временным рядам поляризации VV со спутников Sentinel-1 выявлялись заброшенные пахотные земли на всей территории Китая [99]. Однако одной поляризации оказалось недостаточно, и авторы добавили в исследование оптические данные EVI для поиска не поросшей лесом залежи. Исследование показало, что в Китае в 2020 г. не обрабатывалось 23 % пахотных земель. Точность классификации для 4 934 тестовых площадок составила 94 %. Для картографирования посевов сои и кукурузы на территории США производилось сравнение данных Landsat-8, Sentinel-2, Sentinel-1 и MODIS [73]. В эксперименте исследовались временные ряды каналов видимого и инфракрасного спектра Landsat-8, Sentinel-2 и MODIS, а также поляризации VV, VH и соотношение VH/VV по данным Sentinel-1. Целью машинного обучения на основе метода деревьев решений являлось определение доли пикселей посевов культуры (три класса: малая, средняя, высокая) в тестовых полигонах. В ходе исследования было выявлено, что наихудшая точность наблюдалась для данных MODIS (92 %), точность классификации на основе данных Sentinel-1 всего на 2 % уступает оптическим данным Sentinel-2, а совместное применение оптических и радиолокационных данных позволяет получить максимальную точность (97 %).

Группа исследователей из университета Наварры [75] определяла посевы 14 сельскохозяйственных культур на основе данных Sentinel-1 (VV, VH, VH/VV) на уровне провинции в Испании, а также отдельных муниципалитетов. Точность классификации по Sentinel-1 не превысила 70 %. В ряде исследований производилось объединение радиолокационных и оптических данных для картографирования посевов, где в качестве исходных данных использовались снимки Landsat-8

(или Sentinel-2) и Sentinel-1, а в качестве метода классификации применялся алгоритм RF [109, 151]. При этом наблюдалась значительная разреженность данных, а линейная интерполяция значительно снижала точность классификации [21].

Несмотря на успешное использование отдельных поляризаций Sentinel-1 для картографирования сельскохозяйственных культур, применение специализированных радиолокационных вегетационных индексов (по аналогии с оптическими) представляется более перспективным. В исследовании, проводившемся на территории Германии, одновременное использование месячных композитов индекса RVI, поляризаций VV, VH и отношения VH/VV позволило построить классификатор, чья средняя точность на тестовых участках составила 65 % [125]. Для повышения точности до 80 % авторам пришлось дополнительно рассчитать временные ряды нескольких индексов вегетации по данным Sentinel-2 и Landsat-8, устранить несоответствия в пространственном разрешении, восстановить данные, а также добавить в модель переменные температуры, осадков и влажности. Учёные из университета Твенте (Нидерланды) использовали временные ряды вегетационного индекса SAR двойной поляризации (DPSVI) и модифицированного радиолокационного вегетационного индекса (MRVI) для идентификации посевов восьми сельскохозяйственных культур (кукуруза, картофель, шесть зерновых культур) в Нидерландах [102]. Было установлено, что использование вегетационных индексов повысило точность классификации на 2 % по сравнению с отдельными поляризациями (с 67 до 69 %). Объединение шести зерновых культур в один класс увеличило точность до 80 %.

Использование всего сезонного временного ряда того или иного вегетационного индекса позволяет определять сельскохозяйственную культуру, произрастающую на поле, по окончании сельскохозяйственного сезона. Но не менее (а с практической точки зрения – более) важно уметь идентифицировать сельскохозяйственную культуру уже по ходу сезона. Количество исследований, посвященных этой проблеме, пока не так велико, и зачастую сводится к использованию одного или нескольких космических снимков, полученных в ходе сезона [24, 88, 92]. В работе группы учёных из Тулузы (Франция) временные ряды значений ка-

налов и производных вегетационных индексов, полученных с аппаратуры Landsat-8 (11 снимков), и поляризаций со спутника Sentinel-1 (девять снимков) использовались для классификации пахотных земель на шесть классов (зерновые культуры, кукуруза, рапс, подсолнечник, люцерна, травы) [109]. Исследование производилось на 1 700 полях в сезоне 2014–2015 гг., для распознавания посевов культур применялось около 40 характеристик (каналы, поляризации, вегетационные индексы). Производилась оценка точности классификации в три даты: 29 января, 24 марта и 23 апреля 2015 г. На конец января (три снимка Sentinel-1 и четыре снимка Landsat-8) точность классификации варьировалась от 48 % для подсолнечника до 86 % для зерновых культур. В конце марта (пять снимков Sentinel-1 и семь снимков Landsat-8) точность определения посевов подсолнечника выросла до 67 %, кукурузы с 56 до 62 %. В апреле точность определения посевов рапса выросла до 78 % (с 60 % в марте). Точность для всех остальных культур, кроме подсолнечника, в январе была на 7–9 % ниже, чем в апреле, что в целом даёт возможность раннего определения этих культур. Однако, точность классификации была невелика, а для четырех из шести классов точность оказалась меньше 80 %.

В исследовании китайских учёных, проведенном в 2017–2018 гг., осуществлялась классификация сельскохозяйственных земель в районе города Хэншуй (провинция Хэбэй, КНР) на четыре класса: хлопок, яровая кукуруза, озимая пшеница/яровая кукуруза, деревья [92]. В качестве исходных данных рассматривались временные ряды NDVI и EVI, полученные по данным Landsat-8 и Sentinel-2 (приведены к разрешению 30 м). Для машинного обучения использовалась нейронная сеть ABNet. Показана возможность определения посевов основных сельскохозяйственных культур в конце июня (точность классификации превысила 90 %), то есть через 4 месяца после начала сельскохозяйственного сезона. При этом точность классификации с использованием всего сезонного ряда составляла 97 %.

Учёными из США проводились эксперименты с датой раннего картографирования посевов сельскохозяйственных культур с окном 8 дней [124]. Эти даты для разных культур значительно варьировались. Так, озимая пшеница, соя и куку-

руза определялись с точностью свыше 90 % в начале, середине и конце августа, соответственно. Залежь определялась с высокой точностью в середине августа, люцерна – в конце сентября, а рис и сорго – только в середине ноября. Авторы сделали вывод, что основные сельскохозяйственные культуры США могут быть определены по спутниковым данным в конце августа.

1.3.2 Прогнозирование урожайности сельскохозяйственных культур

Урожайность является одним из основных показателей эффективности агро-промышленного комплекса. Предварительные оценки урожайности используются при планировании и регулировании как внутреннего рынка, так и экспортных операций. Урожайность зависит от природно-климатических условий территории выращивания сельскохозяйственных культур [57].

В последнее время для прогнозирования урожайности сельскохозяйственных культур все чаще используются данные, полученные методами дистанционного зондирования Земли из космоса [66, 133]. В работе американских учёных [136] производилась оценка связи динамики значений 10 вегетационных индексов с динамикой развития растительного покрова и биомассы озимых зерновых культур в течение сельскохозяйственного сезона 2014–2015 гг. на полях в штате Мэриленд (США). Для расчёта значений вегетационных индексов использовался радиометр CROPSCAN. Наиболее сильная связь наблюдалась между значениями индекса NDVI и процентом листовой поверхности ($R^2 = 0,93$), а также треугольным вегетационным индексом (TVI) и биомассой ($R^2 = 0,86$).

В то же время набор метеорологических факторов, включающий как отдельные показатели (температура, влажность и т. д.), так и комплексные характеристики, также может определять урожайность сельскохозяйственных культур [87]. Поэтому, в настоящее время для прогнозирования урожайности сельскохозяйственных культур на районном или региональном уровне наряду с традиционными трендовыми методами и методами аналогов по годам используются регрессионные модели с метеорологическими показателями и данными дистанционного зондирования Земли в качестве независимых переменных [154]. Основным пре-

диктором таких регрессионных моделей обычно выступает максимальное значение вегетационного индекса NDVI для отдельных полей или для территории, рассчитанное по маске конкретной культуры [57]. В Китае производилось прогнозирование урожайности озимой пшеницы для муниципалитетов пяти провинций Китая в 2001–2015 гг. с использованием восьмидневных композитов MODIS; метеорологических (минимум и максимум температуры, средняя влажность, количество осадков) и почвенных характеристик (содержание углерода, кислотный баланс и т. д.), рассчитываемых ежемесячно [108]. Для решения задачи регрессии использовались методы машинного обучения, наибольший коэффициент детерминации ($R^2 = 0,75$) был получен при использовании метода LightGBM (градиентный бустинг). При этом показано, что наибольшая точность прогнозирования наблюдается при использовании значений вегетационных индексов NDVI и EVI в районе максимума вегетации (март-апрель для озимых культур).

В некоторых случаях при моделировании урожайности сельскохозяйственных культур используются маски пахотных земель. Например, они применялись для оценки урожайности озимой пшеницы на всей территории Европы [119]. Значения NDVI и фотосинтетически активной радиации рассчитывались по данным SPOT (пространственное разрешение 1 км), что связано с большой территорией и периодом исследования (1999–2009 гг.). При этом ошибка прогнозирования урожайности (кросс-валидации) сильно варьировалась в разных регионах – от 6 % в Северной Атлантике до 23 % на юге Средиземноморья.

Исследователи из Бостонского университета (США) [78] сравнили эффективность использования маски одной культуры с общей маской пахотных земель в рамках исследования по прогнозированию урожайности кукурузы и сои. В результате включение информации, связанной с фенологией сельскохозяйственных культур, значительно улучшило точность модели. В работе, выполненной в Департаменте сельского хозяйства США [114], исследовалась корреляция между урожайностью сельскохозяйственных культур (ячмень, канола, кукуруза, хлопок, картофель, сорго, соя, сахарная свекла, пшеница, рис) и композитами MODIS (NDVI, EVI, индексом листовой поверхности (LAI)) и т. д.), полученными по мас-

ке сельскохозяйственных культур CDL. Анализ выявил, что наблюдается сильная положительная корреляция средней урожайности, полученной в основных сельскохозяйственных штатах США, и значениями NDVI в середине сельскохозяйственного сезона (то есть в районе максимума вегетации).

Ряд исследований, посвященных использованию значений вегетационных индексов для прогнозирования урожайности сельскохозяйственных культур, проводился и в отечественной науке. Одной из важных работ, где были построены регрессионные модели прогнозирования урожайности сельскохозяйственных культур (на примере озимой пшеницы), стало исследование, проведенное в Институте космических исследований РАН [42]. В качестве предикторов модели выступали индексы NDVI, вычисленные по значениям приборов SPOT и MODIS, метеорологические данные о температуре и осадках, а также созданная (также на основе данных MODIS) в ИКИ РАН маска земель с посевами озимых культур. Детальный анализ показал, что использование временных рядов композитов NDVI за достаточно продолжительный период (10 лет) позволило построить уравнения регрессии ($R^2 > 0,8$) для предсказания урожайности озимой пшеницы в разных регионах России.

Совместная работа Международного университета природы, общества и человека «Дубна» (Московская область) и Национального центра космических исследований и технологий (Алматы, Казахстан) посвящена сравнительному анализу результатов прогнозирования урожайности яровой пшеницы на основе многолетних рядов статистических данных и интегральных индексов вегетации, построенных по данным ДЗЗ. В качестве основы для оценки многолетней динамики растительного покрова выступала попиксельная база ежедневных значений NDVI, сформированная по данным AVHRR NOAA и MODIS Terra на всю территорию Казахстана. На её основе путем выбора максимального суточного значения за соответствующую декаду вычислялись декадные композиты NDVI. Прогноз рассчитывался с учетом априорной вероятности и закономерностей чередования благоприятных, нормальных и засушливых вегетационных сезонов [53]. Для общей оценки хода вегетации использовались интегральные вегетационные индексы:

интегральный индекс условий вегетации (IVCI), интегральный вегетационный индекс (IVI). При расчете использовались средние значения урожайности для благоприятных, нормальных и засушливых сезонов, которые вычислялись по статистическим данным и значениям IVI за соответствующий период [53]. Ошибка прогноза сильно варьировалась между годами (от 5 до 51 %), при этом наибольшая ошибка наблюдалась при прогнозировании в засушливые годы. Авторы сделали вывод, что для повышения точности прогнозирования урожайности яровой пшеницы в Казахстане необходимо учитывать характер текущего цикла солнечной активности, сроки и темпы схода снежного покрова, погодные условия в предшествующие годы [53].

Практически важной задачей видится раннее прогнозирование урожайности сельскохозяйственных культур на муниципальном и региональном уровнях. Под термином «раннее прогнозирование» подразумевается прогнозирование урожайности в период до достижения максимума вегетационного индекса. Для обеспечения возможности раннего прогнозирования на начальных этапах вегетационного периода анализируются закономерности годового хода NDVI [32, 58, 77].

В субъектах Российской Федерации на территории среднего Поволжья модель раннего прогнозирования использовалась для оценки урожайности озимой пшеницы [9]. Установлены зависимости урожайности озимой пшеницы от метеорологических факторов, показана средняя многолетняя динамика коэффициентов корреляции между урожайностью пшеницы и NDVI за 2003–2013 гг. по декадам весенне-летнего периода вегетации. Установлены периоды, когда прогнозирование урожайности возможно с наибольшей точностью. Наиболее тесная связь урожайности озимой пшеницы с NDVI в южных районах Среднего Поволжья выявлена в период со второй декады мая по вторую декаду июня, в период от выхода в трубку до цветения [9]. Однако это значение NDVI фактически является первым максимумом (второй максимум, характерный для яровых культур, наблюдается в конце июля) [42]. Таким образом, рассматриваемый подход по факту является прогнозированием урожайности по максимуму NDVI. Для прогнозирования урожайности озимой пшеницы в конце мая строились нелинейные регрессионные

модели, в которых в качестве параметров использованы значения метеорологических показателей за май, осредненные по территории субъектов [9]. Ошибка прогнозирования урожайности находилась в пределах 5–8 %.

В зарубежных работах также исследовалась возможность прогнозирования урожайности до достижения максимума NDVI. Например, китайскими учёными установлено, что коэффициент детерминации в ходе вегетационного периода растёт с увеличением длины временных рядов вплоть до достижения максимума вегетации. Однако, использование метеорологических характеристик даёт возможность осуществлять прогноз урожайности в более ранние сроки.

Статья японского учёного [141] посвящена использованию значений индекса Wide Dynamic Range Vegetation Index (WDRVI) по данным прибора MODIS и данных реанализа (температура, влажность, количество осадков, коротковолновая радиация) в разные сроки вегетации для прогнозирования урожайности сои и кукурузы на территории США. Результаты показали, что наибольшая корреляция со статистической урожайностью на уровне округа наблюдалась за 13 дней до начала репродуктивного роста кукурузы и за 6 дней до стадии завязывания бобов для сои (стадии, близкие к максимуму вегетационного индекса). Результаты валидации показали, что среднеквадратическая ошибка прогнозирования урожайности методом RF составила 0,539 т/га для кукурузы и 0,206 т/га для сои. В исследовании, проведённом сотрудниками Государственного университета Миссисипи (США), проводилась оценка связи 19 метрик, рассчитанных по временным рядам индексов NDVI и EVI, и урожайностью сои в 18 округах в районе дельты реки Миссисипи [143]. С использованием кросс-валидации выявлено, что среднее значение NDVI к моменту образования бобов и максимум EVI лучше всего подходят в качестве предикторов при построении регрессионных моделей урожайности.

1.4 Выводы по первому разделу

Внедрение методов мониторинга пахотных земель с использованием данных ДЗЗ широко осуществляется на национальном и глобальном уровнях. Масштабные карты пахотных земель являются общедоступными и используются как в за-

дачах мониторинга сельскохозяйственными организациями, так и в качестве исходных данных для проведения научных исследований. Из зарубежных продуктов, предоставляющих данные о сельскохозяйственных угодьях, можно выделить карту пахотных земель CDL, охватывающую территорию США, и LPIS, разработанную для сельскохозяйственного мониторинга в Евросоюзе. В России функционирует ЕФИС ЗСН, содержащая информацию о границах сельскохозяйственных угодий, их типе, а также севообороте на полях всех муниципальных образований Российской Федерации. При формировании карт используются не только информация, вносимая сельскохозяйственными производителями, но и результаты автоматизированного распознавания пахотных земель и сельскохозяйственных культур. Проведенный анализ масштабных карт пахотных земель показал, что их точность сильно варьируется для различных регионов, в зависимости от климатических условий и методов ведения сельского хозяйства.

Выявлено, что в ЕФИС ЗСН наблюдается существенный недостаток достоверных данных о землях сельскохозяйственного назначения Дальнего Востока. В частности, в Хабаровском районе отсутствуют сведения о севообороте на сельскохозяйственных полях за 2021–2022 гг., информация за более ранние годы является неполной и не всегда корректной. Наблюдаются проблемы и в актуальности границ сельскохозяйственных угодий. Поэтому их использование для решения задач мониторинга пахотных земель проблематично. Значительные пробелы в сведениях о сельскохозяйственных полях требуют разработки алгоритма построения региональных карт пахотных земель, учитывающего особенности климата и фенологии сельскохозяйственных культур на Дальнем Востоке.

В России исследования, посвященные созданию масок пахотных земель и сельскохозяйственных культур с использованием данных ДЗЗ, производились преимущественно в муниципальных образованиях европейской части РФ. Отличные от регионов других федеральных округов сортовой состав, сроки сева и уборки урожая затрудняют использование результатов этих работ для регионов Дальнего Востока. Также для Дальнего Востока характерны ярко выраженные сезоны дождей, длительные периоды облачности, наличие аэрозолей или тумана в тече-

ние вегетационного сезона, что приводит к сильной разреженности пригодных для анализа спутниковых данных. Используемые во многих работах методы линейной и полиномиальной интерполяции не позволяют формировать непрерывные временные ряды вегетационных индексов.

Использование всего сезонного временного ряда того или иного вегетационного индекса позволяет определять посевы сельскохозяйственных культур на полях только по окончании сельскохозяйственного сезона. Но для решения задач оперативного мониторинга (оценки хода вегетации, предварительного планирования валового сбора сельскохозяйственных культур, мониторинга использования пашни) необходимо уметь в автоматизированном режиме определять границы сельскохозяйственных полей и выращиваемые на них культуры как можно раньше по ходу сезона. Другой ключевой задачей является раннее прогнозирование урожайности сельскохозяйственных культур на муниципальном и региональном уровнях. Количество исследований, посвященных оперативному распознаванию культур и прогнозированию их урожайности, пока не так велико, и зачастую сводится к использованию данных ДЗЗ, полученных по одному или нескольким безоблачным спутниковым снимкам, что не позволяет оценивать динамику вегетации.

Таким образом, анализ существующих научных работ, показал, что разработка эффективной системы мониторинга пахотных земель на уровне муниципальных образований Дальнего Востока (с учетом региональных особенностей) на основе данных ДЗЗ и машинного обучения является одной из важнейших задач сельского хозяйства.

2 АЛГОРИТМЫ РАСПОЗНАВАНИЯ ПОСЕВОВ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР И НЕИСПОЛЬЗУЕМЫХ ПАХОТНЫХ ЗЕМЕЛЬ С ИСПОЛЬЗОВАНИЕМ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Методика мониторинга пахотных земель, предложенная в диссертационном исследовании, представлена на рисунке 2.1. Мониторинг включает в себя распознавание посевов сельскохозяйственных культур и неиспользуемой пашни в конце сезона (для восстановления сведений о севообороте и для проверки неverified информации, уточнения границ), оперативное распознавание в течение сельскохозяйственного сезона (для корректировки посевной стратегии, мониторинга состояния посевов и оценки посевных площадей), распознавание по многолетним данным (как для восстановления ретроспективы севооборота на полях, так и для оперативного получения информации при отсутствии размеченных данных), а также прогнозирование урожайности в середине сезона (для оценки финансовых рисков во время сбора урожая и планирования импортно-экспортных операций).

Результатом решения большинства задач оперативного мониторинга является построение карт пахотных земель. К основным этапам построения карт пахотных земель относятся: получение и предобработка спутниковой информации, сбор сведений о пахотных землях, построение непрерывных временных рядов индекса вегетации, формирование датасетов, машинное обучение, формирование масок сельскохозяйственных культур, оценка точности классификации, сравнение результатов с данными официальной статистики. Схема построения карты пахотных земель с использованием данных ДЗЗ и методов машинного обучения представлена на рисунке 2.2.



Рисунок 2.1 – Методика мониторинга пахотных земель с использованием данных ДЗЗ и методов машинного обучения



Рисунок 2.2 – Схема картографирования пахотных земель с применением ДЗЗ и машинного обучения

2.1 Получение и предварительная обработка данных

2.1.1 Область исследования

Исследование по распознаванию посевов сельскохозяйственных культур и построению их масок проводилось на территории южной части Хабаровского края: Хабаровского района и части полей, примыкающих к Хабаровскому району в районе имени Лазо (в дальнейшем – Хабаровский район). Общая посевная площадь по данным официальной статистики в Хабаровском районе составила 17 054 га в 2021 г., 18 143 га в 2022 г. и 17 133 га в 2023 г. Пахотные земли в Хабаровском районе находятся на юге Среднеамурской низменности на правом берегу реки Амур к востоку и юго-востоку от города Хабаровска. На рисунке 2.3 показана область исследования и очерченные полигоны полей.

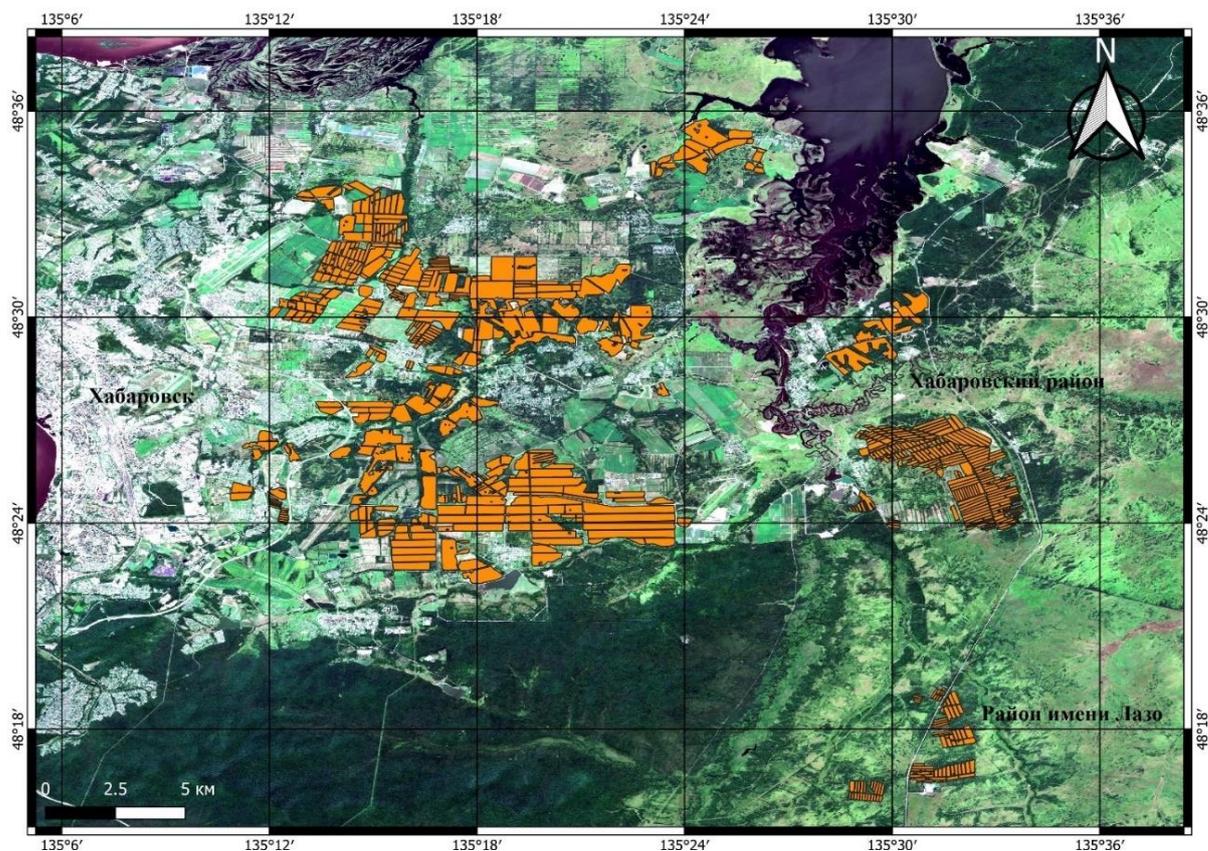


Рисунок 2.3 – Область исследования и полигоны сельскохозяйственных полей
(2023 г.)

Климат и почвенные условия южной части Хабаровского края благоприятствуют возделыванию зернобобовых культур, в первую очередь сои. Посевы сои в 2021–2023 гг. занимали более половины пахотных земель района (54 % в 2021 г., 59 % в 2022 г., 51 % в 2023 г.). Из остальных произрастающих на территории района культур можно выделить зерновые культуры (овёс, пшеница, ячмень), чьи посевы занимали от 12 % (в 2021 и 2022 гг.) до 15 % (в 2023 г.) и кормовые культуры (преимущественно многолетние травы и кукуруза на силос), доля которых составляла от 13 % (в 2021 и 2022 гг.) до 17 % (в 2023 г.).

С 2021 по 2023 г. собирались данные по сельскохозяйственным полям южной части Хабаровского края. Сведения о расположении полей и севообороте предоставлялись сельскохозяйственными производителями и научными организациями, а также собирались в ходе полевых экспедиций. Верификация границ полей и сведений о выращиваемой культуре проводилась в ходе визуального осмотра. Для точного определения границ и подготовки shp-файлов полей использовались космические снимки. Объём собранной и верифицированной информации ежегодно увеличивался. Так, в 2021 г. была получена информация об опытных полях Дальневосточного научно-исследовательского института сельского хозяйства (ДВ НИИСХ). В 2022 г. дополнительно были собраны сведения о севообороте от крупных сельскохозяйственных производителей региона – СХП «Колос» и ПВСК «Волконское», а в 2023 г. – от ООО «Даниловка». Площади исследуемых земель представлены в таблице 2.1.

В 2021 г. были собраны данные о 96 полях: 47 неиспользуемых в течение сельскохозяйственного сезона, 34 с посевами сои, 10 с посевами гречихи, двух полях с многолетними травами (тимофеевка луговая) и трех с посевами зерновых культур (овса). В 2022 г. получена информация о 405 сельскохозяйственных полях: 208 с посевами сои, 64 с посевами зерновых культур (овса, ячменя, пшеницы), 40 полях с многолетними травами (тимофеевкой луговой и клевером), 23 полях с кукурузой, семи полях с гречихой и 63 неиспользуемых полях. В 2023 г. была собрана информация о 520 полях: на 333 из них произрастала соя, на 69 полях росли многолетние травы (тимофеевка, кострец), на 57 выращивались зерновые культу-

ры (ячмень, овёс, пшеница), 10 полей были засеяны гречихой, шесть – кукурузой, а 45 полей не использовались в течение сезона.

Таблица 2.1 – Площадь исследуемых полей в разбивке по сельскохозяйственным культурам в 2021–2023 гг., га

Год	Культура						Всего
	Залежь	Соя	Зерновые	Многолетние травы	Гречиха	Кукуруза	
2021	1 335	1 093	27	47	203	-	2 705
2022	1 552	4 237	1 334	410	291	173	7 997
2023	390	5 866	1 590	424	358	335	8 963

Так же, как и по данным официальной статистики, доминирующей культурой на изучаемых полях являлась соя (40 % от общей площади в 2021 г.; 53 % в 2022 г.; 65 % в 2023 г.).

Многолетнее ежегодное выращивание сои, как наиболее рентабельной культуры, приводит к снижению плодородия почвы. Для поддержания плодородия рекомендуется включать в севооборот зерновые культуры и многолетние травы [4]. Дальневосточные учёные провели 20-летние исследования и показали, что такой севооборот повышает урожайность сои [12]. Суммарная доля овса, ячменя и пшеницы в общей площади используемых пахотных земель составляла 19 % в 2022 г. и 21 % в 2023 г. Многолетние травы (тимофеевка, клевер, кострец) в 2022–2023 гг. занимали чуть более 400 га, что составляет всего 5–6 % от общей площади пашни. Такая диспропорция между посевными площадями сои и других культур указывает на несоблюдение рациональных севооборотов.

Гречиха является отличным медоносом, а также улучшает фитосанитарное состояние полей, благотворно влияет на почвенное плодородие [29]. В системе севооборотов она способствует эффективному очищению полей от сорной растительности. Тем не менее в Хабаровском крае сев гречихи возобновлён (после многолетнего перерыва) только в 2021 г. и носит пока экспериментальный характер. Среди других культур можно выделить кукурузу, выращиваемую в Хабаровском крае, как кормовую культуру (на силос). Количество полей с кукурузой в крае невелико.

Различные факторы, в том числе недостаточное проведение мелиоративных мероприятий, снижение плодородия почв, чрезмерное зарастание полей сорной и древесно-кустарниковой растительностью, привели к тому, что в регионе имеется значительное количество неиспользуемых сельскохозяйственных полей. Введение в севооборот залежных земель является одной из важнейших задач сельского хозяйства Дальнего Востока России. Для решения этой задачи в регионе методы дистанционного зондирования ранее не применялись. Построение маски залежных земель позволит дать реальную оценку доли неиспользуемой пашни.

В качестве источника информации о посевных площадях в 2019 и 2020 гг. использовались границы сельскохозяйственных угодий из ЕФИС ЗСН для Хабаровского муниципального района за 2019 г. По оценкам ЕФИС, площадь сельскохозяйственных полей в Хабаровском районе составила 17 372 га, площадь посевов – 17 103 га. Несоответствие между типом использования земель и сельскохозяйственными культурами (например, в качестве типа может быть указан «сенокос», а в качестве культуры – «соя») говорит о ненадёжности сведений о севообороте. Для большинства полей отсутствуют данные о произрастающих на них культурах, что может значить как то, что на этом поле культура произрастала, но сведения не были внесены в систему, так и то, что это поле являлось залежью. Поэтому непосредственное использование данных ЕФИС для оценки площадей посевов сельскохозяйственных культур, а тем более для прогнозирования урожайности, весьма затруднительно. В число задач мониторинга вошли выявление неиспользуемых земель, уточнение границ полей, а также построение маски основной культуры региона (сои).

2.1.2 Получение спутниковых данных

В качестве исходных спутниковых данных использовались снимки со спутников Sentinel-2A/2B уровня обработки 2A для области исследования, охватывающей правобережную часть Хабаровского района за пятилетний период (2019–2023 гг.). Рассматриваемая область находится между $47^{\circ}52'$ и $48^{\circ}38'$ с.ш., и 135° и $135^{\circ}34'$ в.д. Эта территория снимается спутниковым аппаратом Sentinel-2A,

движущимся по орбитам 60 и 103 с периодичностью в 10 дней (на каждую орбиту), снимки по орбите 103 осуществляются через три дня после съёмки по орбите 60, и аппаратом Sentinel-2B по тем же орбитам с той же периодичностью (через пять дней после съёмки Sentinel-2A). Таким образом, общая частота съёмки обоими спутниками составляет четыре снимка за 10 дней. Для определения сельскохозяйственных культур для каждого года рассматривается сельскохозяйственный сезон. На юге Хабаровского края сельскохозяйственный сезон начинается в третьей декаде апреля – первой декаде мая, когда происходит сев зерновых культур, и заканчивается в третьей декаде октября (к этому времени, в основном, завершается уборка сои).

Снимки Sentinel-2 (по 75 за каждый год) были загружены из спутникового архива ХФИЦ ДВО РАН. Для расчёта NDVI использовались каналы B4 и B8. На каждый год исследования подготовлен shp-файл, включающий границы сельскохозяйственных полей. Для каждого полигона из shp-файла формировался свой массив значений NDVI. Количество таких фреймов (сохранённых в csv-файлах для дальнейшего анализа) равнялось количеству полигонов в shp-файле текущего года.

Серьёзным недостатком оптических спутниковых снимков является влияние облачности на качество данных. Часть снимков с плотным облачным покрытием не несёт практически никакой полезной информации в видимом и ближнем инфракрасном диапазонах. Однако, грубая фильтрация снимков на основе процента облачных пикселей может приводить к потере корректных данных, так как не учитывает локализацию облаков. Так, большое количество «облачных» пикселей снимков может приходиться на области, где сельскохозяйственные земли отсутствуют. И, наоборот, относительно малое количество облаков может закрывать пахотные земли.

Поэтому вполне разумно использовать все имеющиеся снимки территории и применять к ним маску облачности. Для создания масок облачности для каждого полигона применялся продукт SCL (Scene Classification). Продукт SCL имеет разрешение 20 м, поэтому для наложения маски производилась его билинейная ин-

терполяция методом ближайшего соседа для приведения к разрешению вычисленного растра NDVI (10 м). Пиксели со значениями 0 (отсутствие данных), 1 (насыщенные или дефективные), 3 (тени от облаков), 8 (облако со средней вероятностью), 9 (облако с высокой вероятностью), 10 (дымка), 11 (снег) помечались как непригодные для анализа и маскировались. Количество отфильтрованных значений NDVI в рамках shp-файла полей в 2019 г. составило 51 %, в 2020 г. – 59 %, в 2021 г. – 47 %, в 2022 г. – 62 %, в 2023 г. – 60 %. Таким образом, более половины значений NDVI были исключены из анализа вследствие облачности, атмосферных явлений и проблем со съёмкой.

Программа, автоматизирующая обработку изображений, расчёт NDVI и применение масок, написана на языке программирования Python с использованием модулей Rasterio [140], Fiona [152] и Pandas [135].

2.1.3 Формирование непрерывных временных рядов NDVI

Перед построением временных рядов была дополнительно проведена 2σ -фильтрация – для каждого поля рассчитаны среднее значение и среднеквадратическое отклонение NDVI на каждую дату. Все значения, не попадавшие в 2σ -интервал от среднего по полю, в дальнейшем не учитывались. Доля отфильтрованных значений составила в 2021 г. 17 %, в остальные годы находилась в пределах 22–24 %. Аномально высокие или низкие значения NDVI чаще всего связаны либо с погрешностями в границах полей, либо с отклонениями в развитии посевов (неравномерный посев, зарастание сорной растительностью, неравномерное внесение удобрений и т. д.).

Все оставшиеся значения NDVI были объединены во временные ряды: каждому пикселю каждого поля соответствовал свой временной ряд. Пиксели, для которых отсутствовало более половины значений временного ряда, также в дальнейшем не учитывались. Количество таких пикселей относительно невелико: минимальная доля в 2021 г. составила 1,1 %, а максимальная доля (в 2022 и 2023 гг.) – 2,2 %.

В итоге количество релевантных наблюдений значительно варьируется как между годами, так и между пикселями полей (облака и тени от облаков над поля-

ми, аномалии в значениях вегетационного индекса). В разные годы съёмка осуществлялась в разные дни, поэтому чтобы выровнять количество наблюдений в рядах, которые являются входными данными для методов машинного обучения, необходим переход к композитам. В каждом временном ряду значения NDVI разбивались по календарным неделям. При наличии нескольких значений в течение одной календарной недели рассчитывалось среднее значение. Таким образом, все временные ряды композитов NDVI должны включать по 27 значений (с 17 по 43 календарную неделю – с конца апреля по конец октября). Использование композитов уменьшает разреженность в данных, но только для недель, в которые производилась съёмка. Остальные значения нуждаются в восстановлении. Процент отсутствующих значений по годам представлен в таблице 2.2.

Таблица 2.2 – Доля отсутствующих значений в рядах недельных композитов NDVI

Год	Доля отсутствующих значений, %
2019	22,2
2020	35,3
2021	19,8
2022	24,5
2023	28,3

Для восстановления отсутствующих значений вегетационного индекса использовалась аппроксимация с использованием двух первых членов разложения в ряд Фурье. Разложение в ряд Фурье часто используется при обработке сигналов и служит для выделения амплитудной составляющей, что позволяет удалять шум из данных. Ряд Фурье позволяет представить сложную зависимость в виде суммы простых тригонометрических функций. Ранее разложение в ряд Фурье уже использовалось для восстановления временных рядов вегетационных индексов [71, 113]. Два первых члена ряда Фурье (DF) имеют следующий вид:

$$y = a_0 + a_1 \cos(xw) + b_1 \sin(xw) + a_2 \cos(2xw) + b_2 \sin(2xw), \quad (2.1)$$

где w , a_0 , a_1 , a_2 , b_1 , b_2 – параметры функции.

В качестве независимой переменной выступал номер календарной недели, а зависимой переменной – значения NDVI. Для каждого временного ряда рассчитывались значения параметров. Для расчёта параметров шестипараметрической функции необходимо наличие в ряду как минимум шести значений. Недостающие значения временного ряда рассчитывались при подстановке в уравнение (2.1) параметров, где аргументом является номер недели. Определение параметров аппроксимации осуществлялось методом наименьших квадратов (алгоритмом Левенберга-Марквардта [101]) библиотеки `lmfit` [121] языка программирования Python.

Для оценки качества аппроксимации рассчитывалось значение средней относительной ошибки (MAPE) для каждого ряда по формуле:

$$\text{MAPE} = \frac{1}{n-m+1} \sum_{i=m}^n \frac{|V_i^{\text{pred}} - V_i^{\text{obs}}|}{V_i^{\text{obs}}} 100, \quad (2.2)$$

где i – номер недели;

m – неделя начала вегетационного периода (17 неделя);

n – неделя окончания вегетационного периода (43 неделя);

V_i^{pred} – значение аппроксимирующей функции в точке i ;

V_i^{obs} – значение NDVI в точке i .

Такая аппроксимация может использоваться для восстановления всего временного ряда в целях идентификации культуры по окончании сельскохозяйственного сезона. Для решения задачи ранней классификации использовались только данные, доступные в неделю прогнозирования. Для Хабаровского края в качестве периода прогнозирования выбрана 29 календарная неделя (третья декада июля). К этому времени достигается максимум вегетации для зерновых культур, близок максимум NDVI для сои. Для оценки точности аппроксимации использовалась метрика MAPE, рассчитываемая по формуле (2.2), где $m = 17$, $n = 29$. Особенностью такой «ранней» аппроксимации является некоторый дефицит данных: не все временные ряды имели шесть значений, что является критическим для использо-

вания двух первых членов ряда Фурье (шесть параметров), поэтому для проведения такой аппроксимации понадобилась дополнительная фильтрация. Пример аппроксимации временного ряда NDVI для сои представлен на рисунке 2.4. На рисунке 2.5 показана аппроксимация сокращенного ряда (до 29 недели) для того же пикселя изображения.

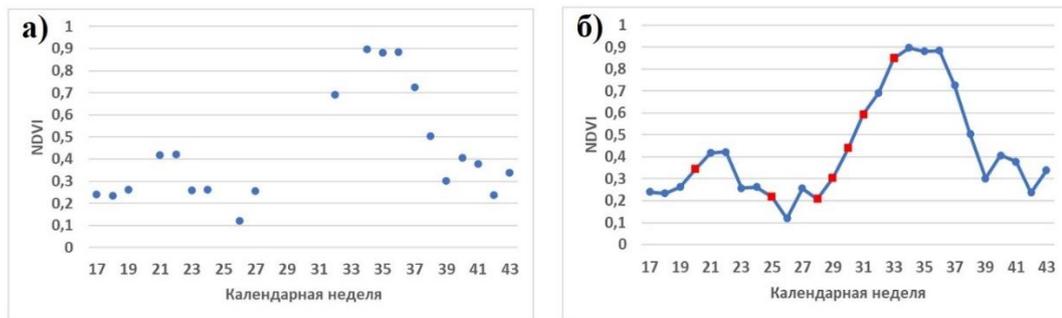


Рисунок 2.4 – Аппроксимация сезонного временного ряда NDVI (на примере одного из пикселей): а) исходные данные, б) восстановленный временной ряд (красным цветом обозначены восстановленные значения)

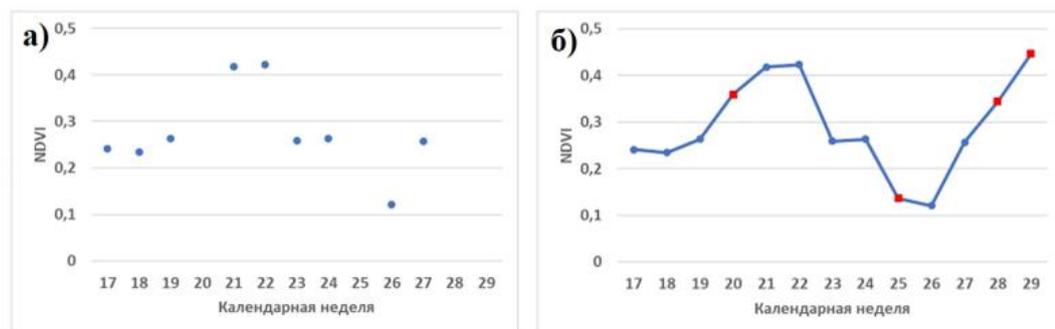


Рисунок 2.5 – Аппроксимация сокращенного временного ряда NDVI (на примере одного из пикселей): а) исходные данные, б) восстановленный временной ряд (красным цветом обозначены восстановленные значения)

Среднее значение ошибки аппроксимации для полных временных рядов варьировалось от 9,8 до 12,3 %, стандартное отклонение – от 3,3 до 5,4 %. При сокращении длины временных рядов средняя MAPE аппроксимации изменялась незначительно и находилась в пределах от 9,1 (2022 г.) до 11,9 % (2019 г.). На рисунке 2.6 показаны диаграммы размаха MAPE аппроксимации для 2021 и 2022 гг.

Можно заметить, что средняя MAPE при аппроксимации сокращенных временных рядов на 2–3 % ниже, чем при аппроксимации в конце сезона. Однако, при этом из-за малого количества данных в таких рядах значительно выросла вариация ошибки, увеличившись с 3,3 до 5,4 % в 2021 г. и с 2,7 до 7,4 % в 2022 г.

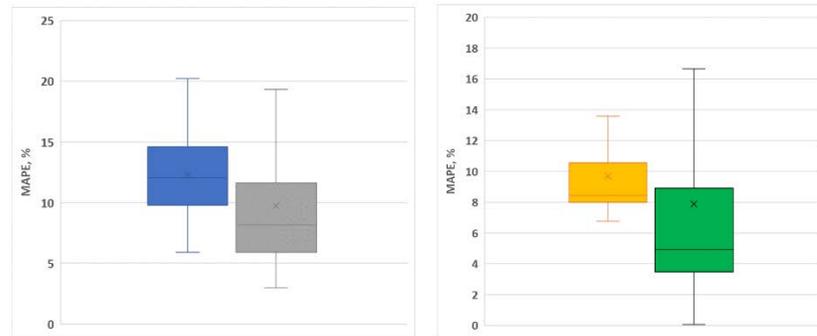


Рисунок 2.6 – Средние значения и отклонения MAPE аппроксимации по всему сельскохозяйственному сезону (синим цветом обозначена диаграмма за 2021 г., оранжевым цветом – за 2022 г.) и по данным на 29 неделю в 2021 г. (диаграмма обозначена серым цветом) и 2022 г. (обозначена зеленым цветом)

2.2 Сезонный ход NDVI и фенология сельскохозяйственных культур

Значения индекса NDVI служат индикатором фотосинтетической активности, поэтому этот индекс активно применяется в задачах мониторинга растительных покровов. В случае сельскохозяйственных полей резкое падение NDVI указывает на произведенную вспашку, внесение гербицидов. Слабый рост NDVI и низкие значения на пике вегетации часто являются признаком аномалий в развитии. Таким образом, построенный сезонный ход NDVI может служить для определения фенологических фаз роста и развития растений. Фенологические фазы для исследуемых культур на юге Хабаровского края и средняя температура каждого месяца представлены на рисунке 2.7.

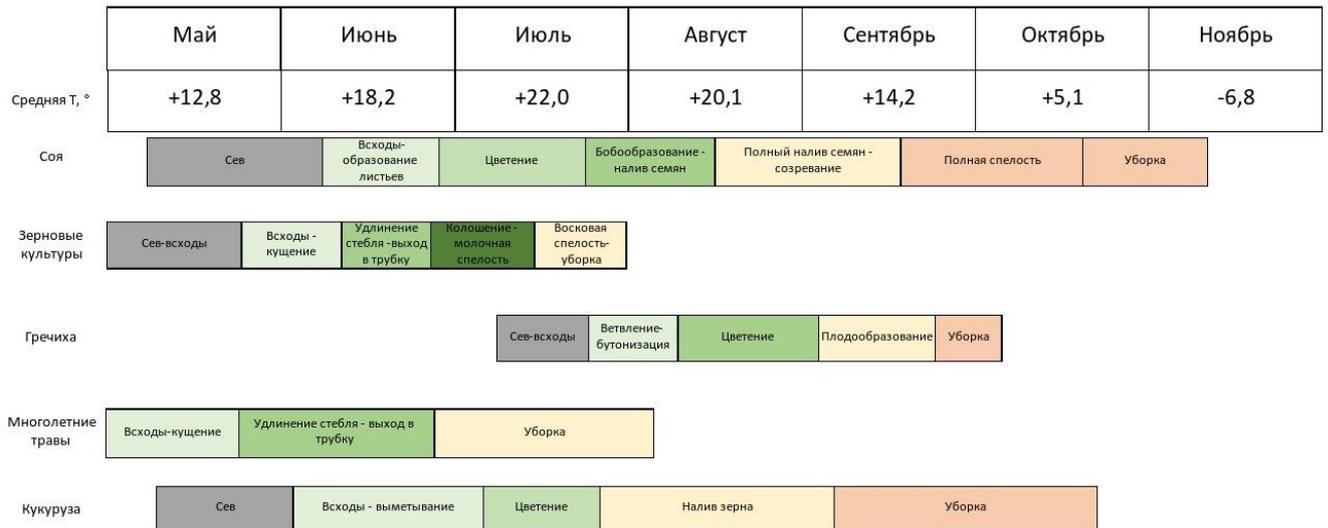


Рисунок 2.7 – Фенологические фазы основных культур и средняя температура месяца в южной части Хабаровского края

Для того, чтобы показать связь NDVI и фенологии разных культур, построены графики восстановленных рядов NDVI исследуемых культур и неиспользуемых земель (залежи).

Сев сои в Хабаровском крае осуществляется, начиная с первой декады мая (чаще всего на опытных полях), но в основном производится во второй половине мая – первой половине июня (20–24 календарные недели). На графиках NDVI (рисунок 2.8) заметны ранние локальные максимумы, связанные с формированием естественного растительного покрова до сева сои (наиболее заметен такой пик на 23-й неделе 2021 г.). Вспашка и внесение гербицидов приводит к падению значений NDVI в июне. Активная вегетация начинается в конце июня в процессе формирования листьев, пик NDVI приходится на окончание стадии цветения и фазу бобообразования (32–33 недели, середина августа). В 2021 г. значения максимума были довольно низкими (около 0,75), в 2022 и 2023 гг. максимум наблюдался на 33 -й неделе, и его значение составило практически 0,9. С окончанием вегетативного роста и началом репродуктивного развития начинается снижение фотосинтетически активной биомассы и падение значения индекса NDVI. Уборка происходит в октябре по достижении полной спелости семян, а иногда из-за неблагоприятных погодных условий осуществляется в ноябре.

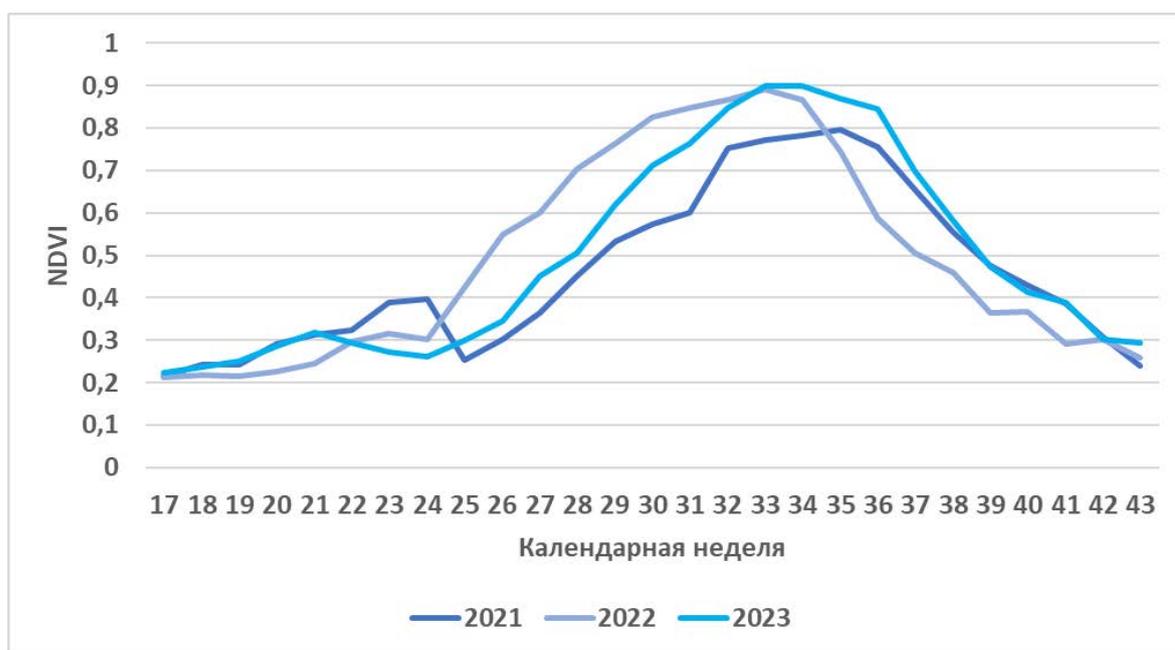


Рисунок 2.8 – Усреднённый сезонный ход NDVI сои в 2021, 2022 и 2023 гг.

Зерновые культуры (овёс, ячмень, пшеница) имеют схожие графики NDVI, поэтому их разделение затруднительно (рисунок 2.9). Именно по этой причине был сформирован один класс – «зерновые». Сев зерновых культур начинается в третьей декаде апреля и продолжается в первой половине мая (17–20 календарные недели), поэтому пика, связанного с ростом сорной растительности в начале вегетационного периода, не наблюдается (рисунок 2.10). Градиент дальнейшего роста NDVI может варьироваться в зависимости от конкретной культуры (рост пшеницы происходит несколько быстрее) и наличия подсева многолетних трав. Самое наибольшее значение NDVI достигнуто в 2022 г. (0,78), когда доля пшеницы в посевах зерновых культур была максимальной. В 2021 и 2023 гг. максимум вегетации менее выражен ($<0,7$). Уборка зерновых осуществляется в конце июля – начале августа (30–31 недели). При этом происходит резкое снижение значений NDVI, в дальнейшем вплоть до окончания сельскохозяйственного сезона значения NDVI стабилизируются на уровне от 0,2 до 0,3. Однако, в 2022–2023 гг. после 32 недели не происходило снижения объема фотосинтетически активной биомассы, что указывает на наличие растительного покрова после уборки зерновых. Чаще всего таким покровом являются многолетние травы, которые используются в многолетнем севообороте и высеваются одновременно с зерновыми культурами.

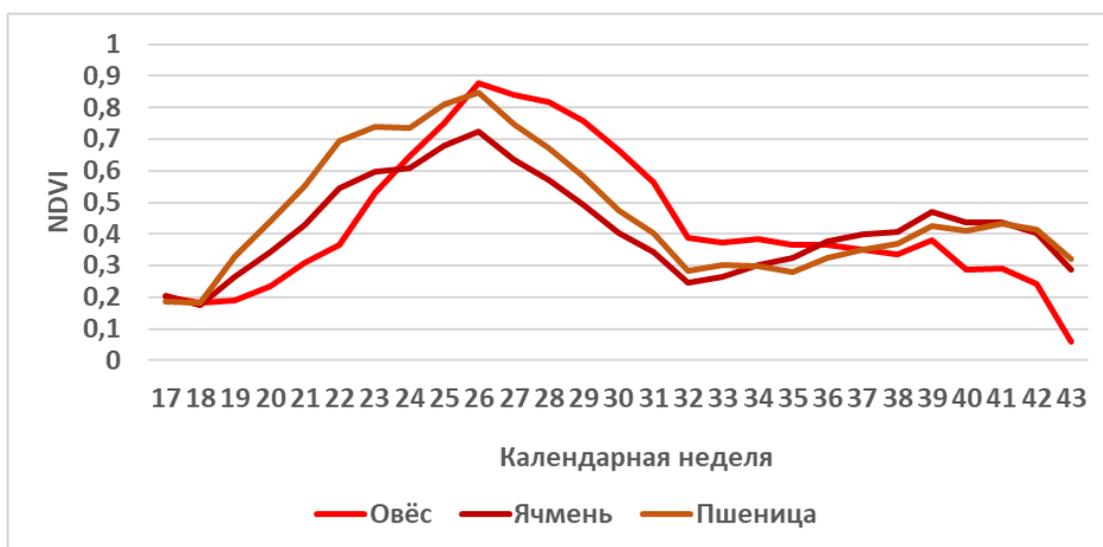


Рисунок 2.9 – Усреднённые графики сезонного хода NDVI для овса, ячменя и пшеницы в 2023 г.

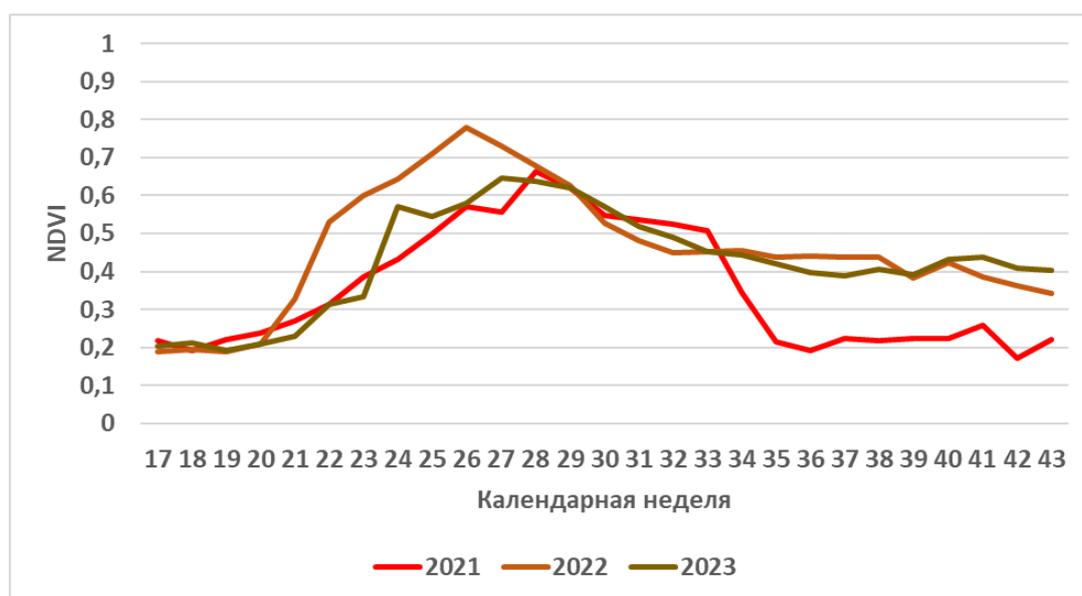


Рисунок 2.10 – Усреднённый сезонный ход NDVI зерновых культур в 2021, 2022 и 2023 гг.

Многолетние травы высеваются под покров зерновых культур и в первый год не скашиваются – такие поля обозначаются как поля с зерновыми культурами (иногда с указанием «с подсевом многолетних трав»). В последующие два года на поле растут преимущественно многолетние травы (возможны всходы оставшихся в почве посевов зерновых). Поля с тимофеевкой, клевером и кострцом второго-

третьего года обозначались как поля с многолетними травами. На рисунке 2.11 видно, что профили сезонного хода NDVI по годам различаются. Это может быть связано как с вариациями в видовом составе этого класса, так и с применением различных сельскохозяйственных практик. Как и для других культур, для трав в 2021 г. отмечались низкие значения NDVI и смещение максимума на несколько недель вправо. Также ранее было отмечено, что в 2021 г. исследовалось всего по три поля с овсом и многолетними травами. По репрезентативным выборкам 2022–2023 гг. видно, что рост биомассы трав начинается рано (19–20 неделя, вторая декада мая), происходит быстрыми темпами, поэтому максимум достигается также довольно рано (0,79 на 24 неделе 2023 г. (в середине июня) и 0,81 на 26 неделе 2022 г. (в конце июня)). Укос обычно производится в июле, при этом в 2023 г. на графике виден чётко выраженный второй пик.

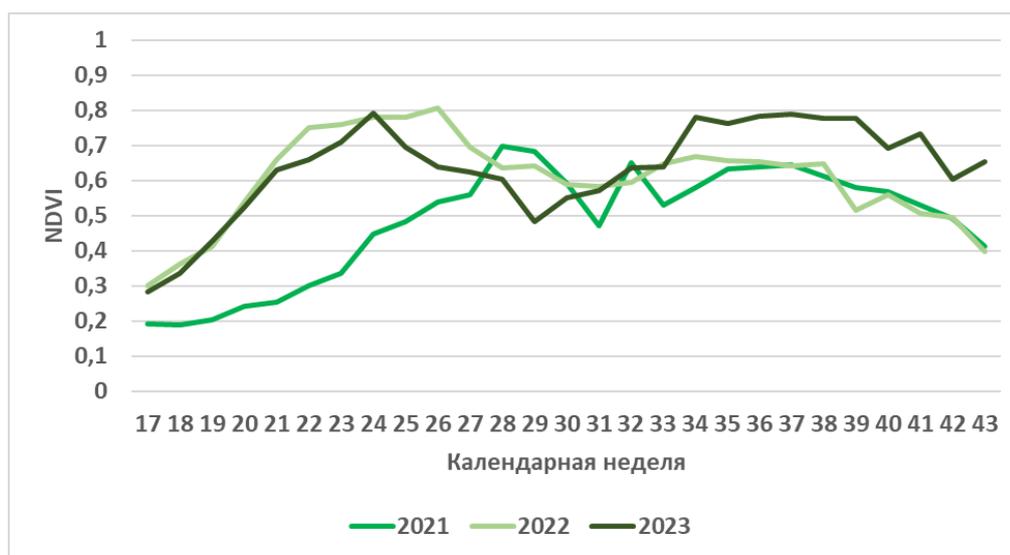


Рисунок 2.11 – Усреднённый сезонный ход NDVI для многолетних трав в 2021–2023 гг.

Вегетационный период гречихи в Хабаровском крае составляет около 70 дней (скороспелый сорт Амурская), что позволяет производить эксперименты со сроками сева. Такие эксперименты хорошо видны на графиках сезонного хода NDVI (рисунок 2.12). График NDVI для гречихи 2023 г. наиболее полно отражает классические (соответствующие рекомендуемым) сроки выращивания этой теплолюбивой культуры: сев осуществляется в первой половине июля (27–28 календарные

недели), максимум вегетации наблюдается в конце августа (34–35 неделя) в конце стадии цветения и в начале стадии плодообразования, а уборка производится в сентябре. Ход NDVI до 28 недели не относится к росту гречихи и описывает естественную вегетацию до её сева. В 2021 г. ход вегетации сдвинут на пару недель (что связано с высокой засоренностью полей, чей максимум оказался сравним с максимумом самой гречихи), а значения NDVI приблизительно на 0,1 меньше, чем в 2023 г. В 2022 г. сев произведен на месяц раньше, в начале июня (22–23 недели), вегетативный рост заканчивался уже к началу августа, а уборка осуществлялась в конце августа – начале сентября.

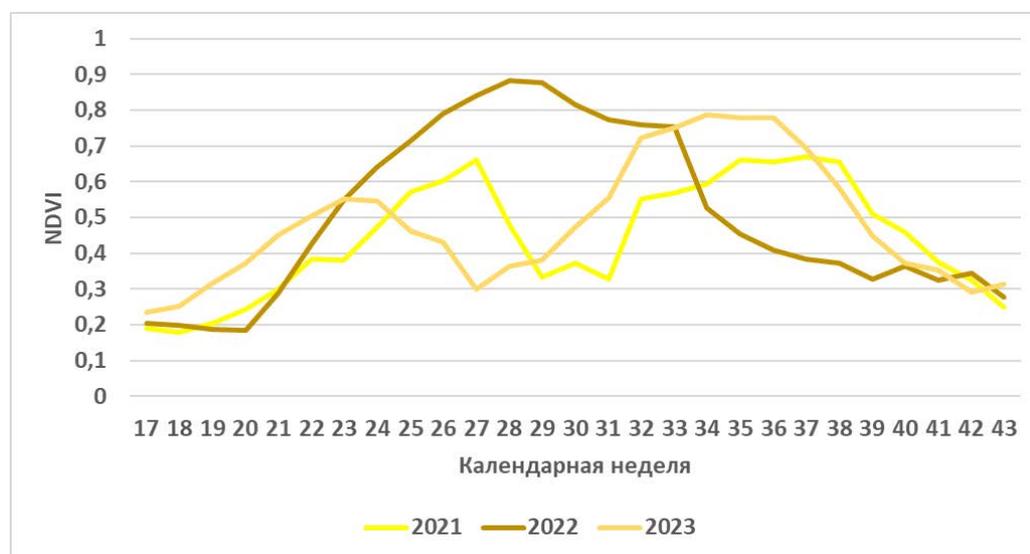


Рисунок 2.12 – Усреднённый сезонный ход NDVI для гречихи в 2021–2023 гг.

Кукуруза в Хабаровском крае выращивается как на силос, так и на зерно. Сев осуществляется в конце мая – начале июня, через две недели начинается формирование стебля и листьев, фаза цветения приходится на август, созревание зерна происходит в конце сентября – начале октября. На рисунке 2.13 приведены графики NDVI кукурузы для 2022–2023 г. В 2022 г. рост NDVI происходил быстрее, чем в 2023 г., но максимумы NDVI наблюдались в схожие сроки (на 33–34 календарной неделе, конец августа) и практически совпадали по значениям (0,85–0,87). Во второй половине сезона (после прохождения максимума) графики имеют схожий вид.

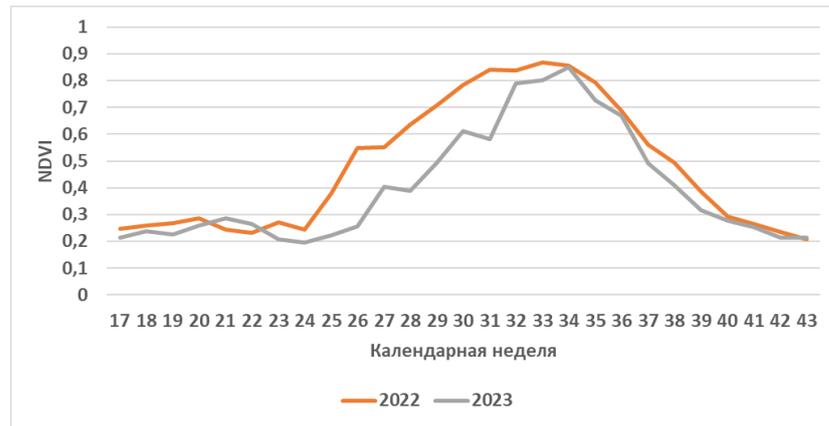


Рисунок 2.13 – Усреднённый сезонный ход NDVI для кукурузы в 2022 и 2023г г.

Залежь представляет собой неиспользуемые пахотные земли, поросшие сорной, кустарниковой и древесной растительностью, либо заболоченные. Значения NDVI начинают расти с начала весны, находятся на стабильном уровне 0,7–0,8, и равномерно снижаются в течение осени (рисунок 2.14).

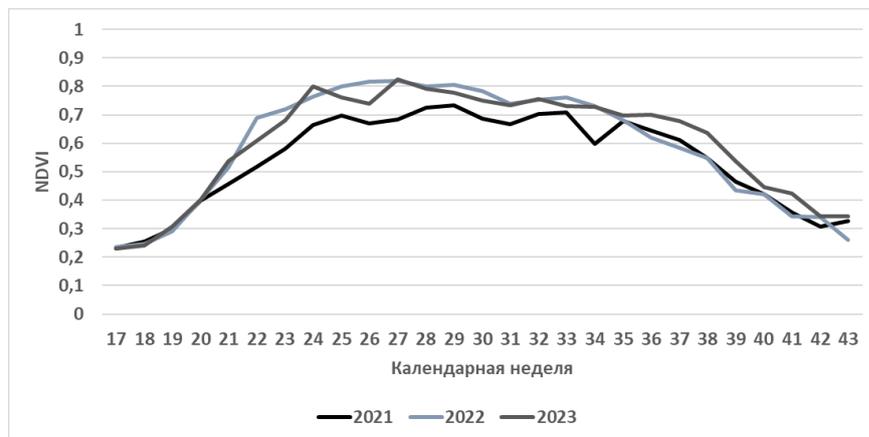


Рисунок 2.14 – Усреднённый сезонный ход NDVI для залежи в 2021–2023 гг.

На рисунке 2.15 представлен усреднённый сезонный ход NDVI для разных сельскохозяйственных культур и неиспользуемых земель Хабаровского района в 2023 г. Каждая культура имеет характерный профиль сезонного хода NDVI. Уже в начале вегетационного периода наблюдается резкий рост NDVI для многолетних трав и залежи, сезонный ход схож до момента начала укоса трав (24–25 календарные недели). Максимум для зерновых культур достигается раньше, чем для сои, гречихи и кукурузы. График NDVI гречихи имеет два чётких пика, в то время как

для кукурузы и сои – один, приходящийся на 32–34 календарные недели. Таким образом, сезонные ряды индекса NDVI могут использоваться для распознавания посевов сельскохозяйственных культур в течение сельскохозяйственного сезона. Самыми близкими классами (с точки зрения сезонного хода NDVI) видятся соя и кукуруза – эти культуры имеют схожие сроки сева и достижения максимума. Использование многолетних данных позволяет учитывать значительную вариацию рядов NDVI между годами, связанную с применением различных сельскохозяйственных практик, погодными условиями и видовым составом (внутри групп), что позволит использовать обученный на данных 2021–2023 гг. классификатор при построении масок сельскохозяйственных культур и залежи в 2019–2020 гг.

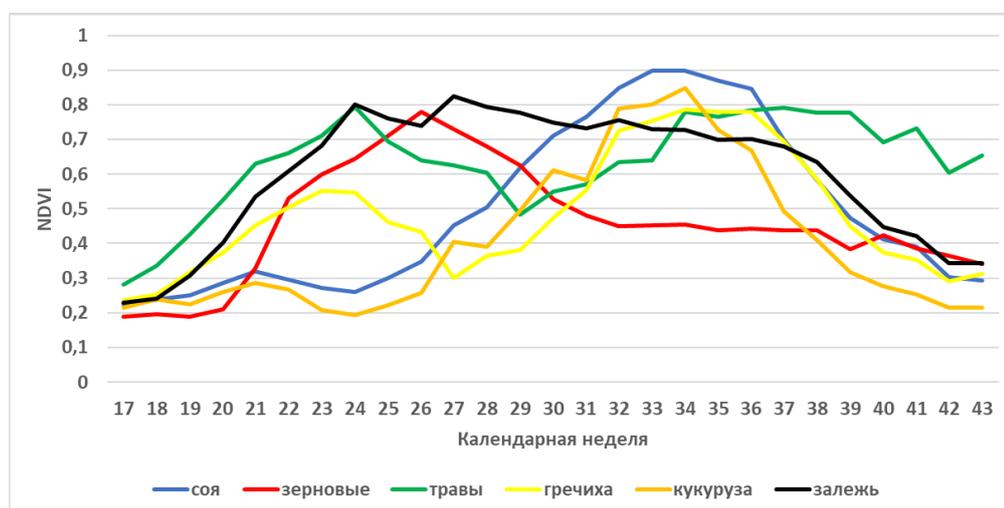


Рисунок 2.15 – Усреднённый сезонный ход NDVI для пахотных земель Хабаровского района в 2023 г.

2.3 Машинное обучение и оценка точности карт

2.3.1 Формирование датасетов для обучения

Временные ряды NDVI за 2019–2023 гг., прошедшие процедуру фильтрации и восстановленные с использованием аппроксимации (см. 2.1.3), были объединены в датасеты. Причём на каждый год (кроме 2019 и 2020 гг.) приходилось по два датасета: полный сезонный и сокращённый (до 29 недели) для решения задачи

раннего распознавания посевов. Для разметки временных рядов использовались сведения о севообороте.

Для всех шести датасетов за 2021–2023 гг. в целях оценки качества распознавания посевов проводилась 10-кратная кросс-валидация с использованием всех прошедших фильтрацию временных рядов NDVI. Разбиение на 10 подмножеств велось на уровне полей, то есть ряды NDVI с одного поля гарантированно попадали в одно подмножество. Такое разбиение позволяет избежать переобучения модели. Количество временных рядов и их распределение в датасетах (2021–2023 гг.) представлено в таблице 2.3. Датасет 2021 г. включает в себя 251 196 временных рядов NDVI, из них залежи – 49,4 %. Из оставшейся половины рядов NDVI основную массу составляли ряды сои – 78,9 %. Другие культуры в структуре посевов представлены гречихой (14,7 %), многолетними травами (4,4 %), зерновыми культурами (1,9 %). Получение от хозяйств региона данных о севообороте и проведение полевых экспедиций в 2022 г. позволили значительно увеличить количество полей, вошедших в исследование, а следовательно, и количество временных рядов. Количество временных рядов NDVI для залежи практически не изменилось (в то время как доля залежи в датасете уменьшилась до 18,9 %). Таким образом, в 2022 году 81,1 % исследуемых рядов NDVI относились к посевам культур: из них более половины (62 %) составили ряды сои, до 20,1 % увеличилась доля зерновых культур, 6,4 % рядов были размечены как «многолетние травы». Доли гречихи и кукурузы (данные для которой отсутствовали в 2021 г.) в структуре посевов оказались незначительны – 4,5 и 2,7 %, соответственно. Множество временных рядов для 2023 г. являлось самым большим и включало в себя 828 445 рядов, при этом основное внимание в этом году уделялось именно реальным пахотным землям (доля залежи составила всего 4,3 %). Доля рядов NDVI для сои в общем количестве рядов сельскохозяйственных культур составила 69,4 %, зерновых культур – 17,7 %. Остальные культуры представлены слабо – 4,9 % многолетних трав, 4,1 % гречихи и 3,9 % кукурузы. Во всех датасетах наблюдается неравномерность распределения временных рядов по классам. Связано это в первую очередь с доминированием посевов сои на полях Хабаровского края. Размер датасетов сокращённых времен-

ных рядов составил: в 2021 г. – 267 158, в 2022 г. – 716 118, в 2023 г. – 820 263 ряда. По результатам кросс-валидации генерировались карты пахотных земель и маски для каждого из классов за 2021–2023 гг.

Таблица 2.3 – Распределение сезонных временных рядов NDVI по классам в выборках по годам

Год	Культура						Всего
	Залежь	Соя	Зерновые	Многолетние травы	Гречиха	Кукуруза	
2021	124 271	100 215	2 457	5 599	18 654	–*	251 196
2022	129 749	390 455	119 812	37 219	26 737	15 868	719 840
2023	35 693	550 223	140 410	36 825	32 608	30 826	828 445

* сведения о полях с культурой отсутствуют

После проведения оценки точности кросс-валидации все сокращенные временные ряды для основных классов (залежь, соя, зерновые культуры, многолетние травы) за 2021–2023 гг. объединены в одно обучающее множество для восстановления сведений о севообороте на полях Хабаровского района и уточнения их границ в 2019–2020 гг.

Сев гречихи в Хабаровском районе возобновлён только в 2021 г., поэтому распознавание посевов этой культуры в 2019–2020 гг. не осуществлялось. Также не производилось распознавание посевов кукурузы ввиду недостаточного объёма выборки, а для удаления немногочисленных полей с кукурузой из маски сои использовались данные ЕФИС ЗСН. Подобный анализ производился и для выявления полей с картофелем (не вошедшим в исследование), который является распространённой культурой в дачных хозяйствах региона, но слабо представлен на полях сельскохозяйственных производителей.

В качестве тестового множества выступали сокращённые временные ряды за 2019–2020 гг. Верифицированная информация о границах полей и севообороте в эти годы отсутствовала, поэтому ряды NDVI не размечались. Количество временных рядов после фильтрации в 2019 г. составило 2 581 106, в 2020 г. – 2 566 773. Такое большое количество пикселей пахотных земель указывает на переоценку количества и размеров сельскохозяйственных полей в районе. По результатам

классификации составлены карты для четырёх исследуемых классов («soя», «залежь», «зерновые культуры» и «многолетние травы») в 2019 и 2020 гг.

Затем была проведена оценка посевной площади сои (основной культуры Дальнего Востока), а также площади неиспользуемых в ходе сезона земель. Учитывая, что площадь одного пикселя изображения Sentinel-2 составляет 100 м^2 , для получения этих площадей количество временных рядов, классифицированных как «soя» и как «залежь», умножено на площадь одного пикселя, а затем переведено в га ($1 \text{ га} = 10\,000 \text{ м}^2$). Полученные результаты сравнивались с данными официальной статистики (База данных показателей муниципальных образований [5]) и значениями, внесёнными в ЕФИС ЗСН.

2.3.2 Машинное обучение для решения задачи классификации

Для решения поставленных задач в качестве метода машинного обучения выбран метод гистограммного градиентного бустинга (Histogram Gradient Boosting). Метод градиентного бустинга [82] основан на применении композиции деревьев решений. Основное отличие этого метода от метода RF (наиболее часто применяемого при решении задач классификации и также основанного на деревьях решений) заключается в том, что обучение выполняется последовательно. На каждой итерации вычисляются отклонения предсказаний уже обученного ансамбля на обучающей выборке. Следующая модель, добавляемая в ансамбль, будет предсказывать эти отклонения. Таким образом, добавление предсказания нового дерева к предсказаниям обученного ансамбля, уменьшает среднее отклонение модели, что является целью оптимизационной задачи. Новые деревья добавляются в ансамбль до тех пор, пока ошибка уменьшается, либо пока не выполняется одно из правил «ранней остановки». Градиентный бустинг считается гибким, быстрым в вычислениях алгоритмом, который работает даже с разреженными данными. Важной особенностью градиентного бустинга (как и других методов, основанных на ансамблях деревьев решений) является его повышенная устойчивость к несбалансированности выборок [98, 79], что является важным аргументом в его использовании при картографировании

пахотных земель с крайне неравномерным распределением площадей под посевы различных культур.

Ранее этот алгоритм уже успешно зарекомендовал себя в исследованиях для задач составления карт растительного покрова [111, 106]. Гистограммный градиентный бустинг представляет собой упрощенную, высокопроизводительную реализацию градиентного бустинга в библиотеке `scikit-learn` [142] языка программирования Python, разработанную специально для классификации больших наборов данных. Этот алгоритм предварительно группирует входные данные в небольшие группы (обычно 256 групп) по значениям. Такое значительное сокращение количества точек разбиения позволяет алгоритму использовать целочисленные структуры данных (гистограммы), а не полагаться на отсортированные непрерывные значения при построении деревьев.

Установлено, что использование бустинга для решения задачи классификации при распознавании посевов сельскохозяйственных культур Хабаровского района в 2021–2022 гг. позволило сократить время обучения на центральном процессоре более чем в 10 раз по сравнению с методом RF. При этом точность классификации значимо не менялась. Такое преимущество в скорости выполнения алгоритма важно в условиях ограниченности ресурсов при использовании больших датасетов многолетних данных.

Параметрами алгоритма являются минимальное количество образцов в узле, максимальное количество листьев в узле и количество итераций. В качестве значений первых двух параметров выбраны 20 и 31 (значения по умолчанию). Проведенные эксперименты показали, что эти значения не влияют на точность классификации. Количество итераций увеличено со 100 (значение по умолчанию) до 300, что позволило незначительно (на 0,3 %) увеличить точность, не потеряв в производительности алгоритма. Дальнейшее увеличение количества итераций не давало прироста в качестве модели.

2.3.3 Оценка точности классификации

Для оценки качества классификаторов при составлении карт используются такие метрики, как общая точность (overall accuracy, OA), точность со стороны пользователя карты (user accuracy, UA), точность с точки зрения создателя карты (producer accuracy, PA) и метрика F1. Значения всех этих метрик рассчитываются из матрицы несоответствий (confusion matrix).

Матрица несоответствий представляет собой квадратную матрицу размерности $n \times n$, где n – количество классов. В матрице несоответствий каждый столбец представляет фактический класс, а каждая строка – предсказанный класс. Каждый элемент матрицы X_{ik} обозначает количество пикселей класса k , попавших в класс i при классификации. Диагональные элементы матрицы представляют собой количество правильно классифицированных пикселей. Отношение суммы диагональных элементов (истинно положительных пикселей, TP) к сумме всех элементов матрицы ошибок N (выраженное в процентах) представляет собой метрику OA (общей точности):

$$OA = \frac{TP}{N} \cdot 100 \%. \quad (2.3)$$

Матрица несоответствий также служит для определения количества пикселей класса k ($k \in [1, n]$), которые были ошибочно отнесены к другим классам (ложно-отрицательные пиксели FN_k). PA представляет собой точность карты с точки зрения ее составителя, или производителя. Эта метрика представляет собой частоту, с которой реальные объекты на местности правильно отображаются на классифицированной карте, или вероятность того, что определенный тип растительного покрова данной территории на местности классифицирован правильно. PA определяется количеством участков, классифицированных точно, деленным на общее количество участков для данного класса:

$$PA_k = \frac{TP_k}{TP_k + FN_k}. \quad (2.4)$$

В матрице несоответствий также можно подсчитать количество пикселей, ошибочно отнесенных к классу k (FP_k). UA представляет собой точность с точки зрения пользователя карты, а не ее составителя. UA представляет собой частоту, с которой значение класса, обозначенное на карте, соответствует действительности, то есть является показателем надежности карты. UA является дополнением к PA и определяется общим числом правильно определенных участков для конкретного класса, деленным на сумму элементов строки k :

$$UA_k = \frac{TP_k}{TP_k + FP_k}. \quad (2.5)$$

Показатель F1 можно интерпретировать как среднее гармоническое значение метрик OA и PA , которое варьируется от 0 до 1. Относительный вклад этих двух метрик в интегральный показатель F1 одинаков:

$$F1_k = \frac{2 * UA_k * PA_k}{UA_k + PA_k}. \quad (2.6)$$

Значения всех четырёх описанных метрик позволяют правильно интерпретировать результаты классификации, оценить качество классификаторов (даже при дисбалансе датасетов), определить, для каких классов характерны несрабатывания и ложные срабатывания алгоритма. Для оценки эффективности классификатора важно также определить количество сельскохозяйственных полей, для которых культура (и её отсутствие) определена верно. Количество пикселей, отнесенных классификатором к тому или иному классу, определяло класс для каждого поля, т. е. участку присваивалась метка самого распространённого определённого алгоритмом класса в границах поля. Расчёт точности классификации на уровне полей позволяет наиболее наглядно оценить качество модели, так как именно уровень полей чаще всего используется при оценке качества карт на муниципальном и региональном уровне.

2.4 Выводы по второму разделу

Предложенная методика мониторинга пахотных земель позволяет как восстанавливать сведения о произрастающих на полях сельскохозяйственных культурах

по окончании периода вегетации, так и оперативно строить карты пахотных земель уже по ходу сезона.

Для построения региональных карт пахотных земель важно наличие качественных данных наземных наблюдений – границ сельскохозяйственных полей и сведений о севообороте. Поэтому при проведении исследования важно сформировать репрезентативную (включающую участки со всеми основными сельскохозяйственными культурами) выборку полей, для которых информация о севообороте является надежной. Также необходимо дополнительно верифицировать полученную информацию как путем анализа спутниковых снимков, так и в ходе полевых экспедиций. В качестве исходных данных ДЗЗ предложено использовать временные ряды NDVI, полученные по снимкам спутников Sentinel-2A/2B с разрешением 10 м.

Для удаления проблемных участков полей из обучающей выборки производится 2σ -фильтрация значений NDVI, а для выравнивания количества наблюдений в рядах производится расчет недельных композитов за весь период вегетации.

Для восстановления отсутствующих значений временных рядов композитов предложено использовать аппроксимацию временных последовательностей NDVI с использованием ряда Фурье. Для решения задачи оперативного распознавания сельскохозяйственных культур аппроксимация производится для сокращенных временных рядов.

Автоматизированные классификаторы строились на базе метода гистограммного градиентного бустинга. Выбор этого метода обусловлен его высокой гибкостью и скоростью в сочетании с высокой точностью классификации.

Использование предложенной методики для построения карт пахотных земель также позволяет оценивать площадь, занимаемую посевами сельскохозяйственных культур, а также площадь неиспользуемых в ходе сезона земель для сельскохозяйственной аналитики и экспертизы.

3 АНАЛИЗ РЕЗУЛЬТАТОВ РАСПОЗНАВАНИЯ ПОСЕВОВ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР И НЕИСПОЛЬЗУЕМЫХ ПАХОТНЫХ ЗЕМЕЛЬ

3.1 Оценка точности построения карт пахотных земель в Хабаровском крае в 2021–2023 гг.

3.1.1 Построение масок сельскохозяйственных культур по полным сезонным временным рядам NDVI

Проведено автоматизированное распознавание посевов сельскохозяйственных культур на полях Хабаровского района с использованием классификатора на основе гистограммного градиентного бустинга. Для решения задачи классификации использовались восстановленные сезонные временные ряды недельных композитов NDVI за вегетационный период (конец апреля – конец октября) 2021–2023 гг.

Общая точность кросс-валидации в 2021 г. составила 97,3 %. На рисунке 3.1 представлена матрица несоответствий для классификатора в 2021 г. Для трех классов («соя», «гречиха» и «залежь») значения метрики РА превысили 0,95: 123 210 ряда NDVI залежи из 124 271 (98,7 %) правильно распознаны, 96 775 из 100 215 временных рядов сои распознаны верно (97,7 %), из 18 654 временных рядов NDVI гречихи верно классифицированы 17 811 (96,4 %). РА распознавания слабо представленных в выборке классов «зерновые культуры» и «многолетние травы» оказалась ниже – 0,82 для зерновых (три небольших поля с посевами овса общей площадью в 27 га) и 0,85 для многолетних трав (два поля с тимофеевкой луговой общей площадью 47 га). На каждом из полей с посевами зерновых были обнаружены проблемные участки (их площадь составила 17 % от общей площади полей).

соя	96775	125	2420	94	801
зерновые	18	2021	5	0	413
травы	53	12	4736	322	476
гречиха	190	11	76	17811	566
залежь	849	99	36	77	123210
	соя	зерновые	травы	гречиха	залежь

Рисунок 3.1 – Матрица несоответствий классификации с использованием сезонных рядов NDVI (2021 г.)

Количество рядов NDVI многолетних трав было переоценено за счёт выявления многолетних трав на полях с соей (рисунок 3.2). Это может быть связано с засоренностью полей. Несмотря на то, что использование ансамблевых методов снижает влияние несбалансированности выборок, полностью устранить проблему искажения рассчитываемых метрик не удалось. При переходе от отдельных пикселей на уровень отдельных участков (полей) значение ОА меняется незначительно и составляет 98,9 %: из 96 полей, исследуемых в 2021 г., культура (или её отсутствие) определена верно на 95. Ошибка идентификации культуры на уровне поля произошла только на одном поле с посевами сои. На абсолютном большинстве полей точность распознавания внутри границ полигона превысила 95 %.

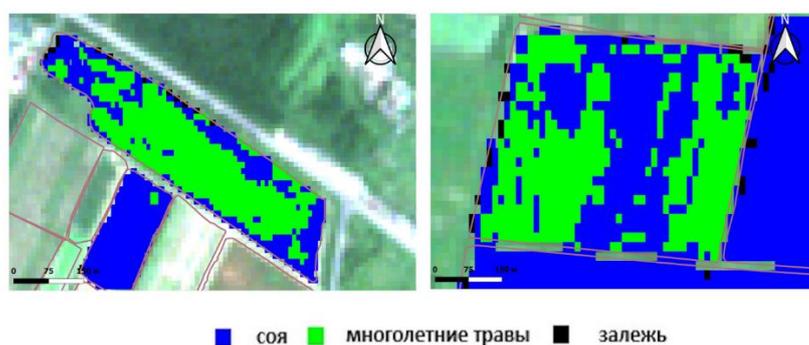


Рисунок 3.2 – Распознавание пикселей многолетних трав на полях с соей в 2021 г.

В ходе классификации были получены маски залежи, сои, многолетних трав, гречихи, зерновых культур и построена карта пахотных земель на 2021 г. (рисунок 3.3).

В выборке за 2022 г. присутствовали временные ряды NDVI для посевов кукурузы. Общая точность кросс-валидации уменьшилась незначительно по сравнению с 2021 г. и составила 96,3 %. Матрица несоответствий классификации с использованием сезонных рядов NDVI в 2022 г. представлена на рисунке 3.4. Максимальное значение метрики F1 зафиксировано для самого представленного в выборке (390 455 рядов) класса «соя» – 0,98. Для зерновых культур и залежи значение F1 составило 0,96. Для двух менее представленных классов – «многолетние травы» и «гречиха» (37 219 и 26 737 рядов, соответственно) – значение F1 также оказалось достаточно высоким (0,94), причём в обоих случаях UA оказывалась выше, чем PA (0,95 против 0,92), то есть количество рядов NDVI, отнесённых классификатором в эти классы, оказалось на 4 % меньше, чем в исходном датасете. Незначительная часть посевных площадей многолетних трав (4 %) и гречихи (2 %) была распознана как залежь. Наличие таких небольших вкраплений залежи, особенно у границ сельскохозяйственных полей, не является аномалией.

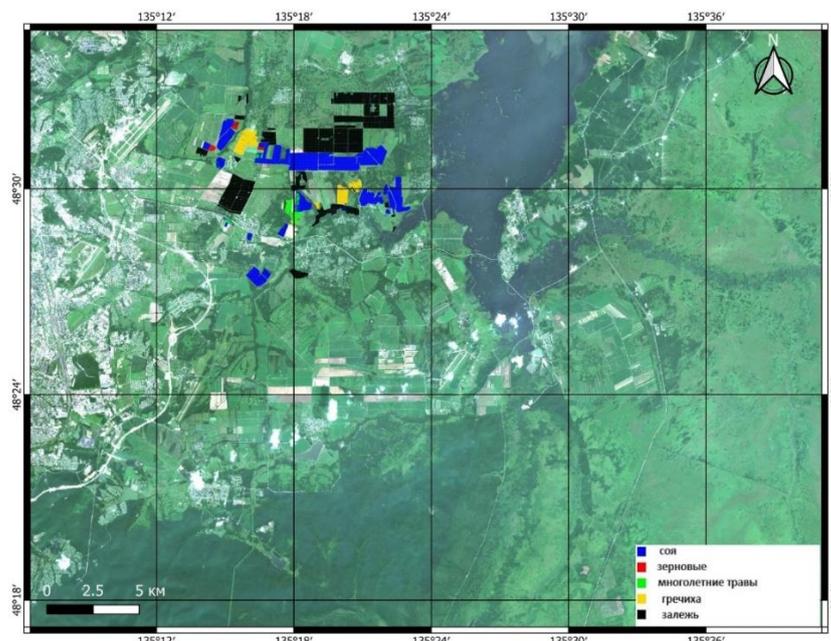


Рисунок 3.3 – Карта пахотных земель, построенная с использованием сезонных композитов NDVI и метода гистограммного градиентного бустинга (Хабаровский район, 2021 г.)

соя	383898	2601	148	193	1609	2006
зерновые	1078	115585	395	807	99	1848
травы	537	424	34508	11	84	1655
гречиха	289	820	1	24638	344	645
кукуруза	6978	26	16	22	8767	59
залежь	1455	916	1166	145	105	125962
	соя	зерновые	травы	гречиха	кукуруза	залежь

Рисунок 3.4 – Матрица несоответствий классификации с использованием сезонных рядов NDVI (2022 г.)

На рисунке 3.5 представлен усреднённый сезонный ход для временных рядов NDVI, отнесённых классификатором к классу «соя» и «кукуруза» в 2022 г. Из-за доминирования сои в структуре посевов (390 455 рядов сои против 15 868 рядов кукурузы) при оценке временных рядов кукурузы у классификатора преобладает ошибка второго рода – количество рядов, классифицированных как «кукуруза», составило всего 11 008 рядов (что в полтора раза меньше представительства класса на входе). В то же время, случаи распознавания других классов (кроме сои) на полях с кукурузой и случаи определения участков кукурузы на полях других классов носят единичный характер.

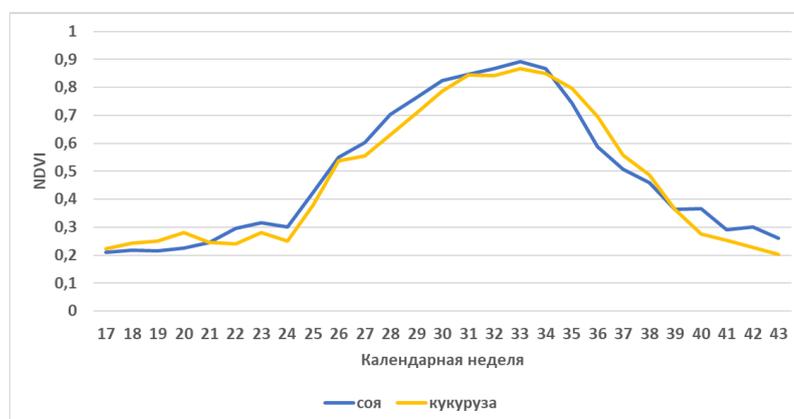


Рисунок 3.5 – Графики сезонного хода NDVI для рядов, отнесённых к классам «соя» и «кукуруза» в 2022 г.

Точность идентификации культур на сельскохозяйственных полях в 2022 г. оказалась достаточно высокой и составила 98 %. Из 405 полей культура была верно определена на 400. Все пять ошибок идентификации были совершены для полей с посевами кукурузы. По результатам распознавания получены маски залежи, сои, многолетних трав, гречихи, зерновых культур и кукурузы и построена карта пахотных земель на 2022 г. (рисунок 3.6).

В 2023 г. были построены сезонные ряды композитов NDVI для 520 полей. Общая площадь исследуемых полей составила 8 963 га. Общая точность распознавания залежных земель, зерновых культур, многолетних трав, сои, гречихи и кукурузы оказалась достаточно высокой ($OA = 96,3 \%$). Наличие в выборке большого количества рядов NDVI сои (550 223) и зерновых культур (140 410) позволило достичь высокой точности их распознавания ($F1_{\text{соя}} = 0,98$, $F1_{\text{зерновые}} = 0,97$). Для многолетних трав и залежи значение метрики $F1$ составило 0,94 ($PA_{\text{травы}} = 0,9$; $PA_{\text{залежь}} = 0,94$; $UA_{\text{залежь}} = 0,94$). Матрица несоответствий кросс-валидации с использованием сезонных рядов NDVI в 2023 г. представлена на рисунке 3.7.

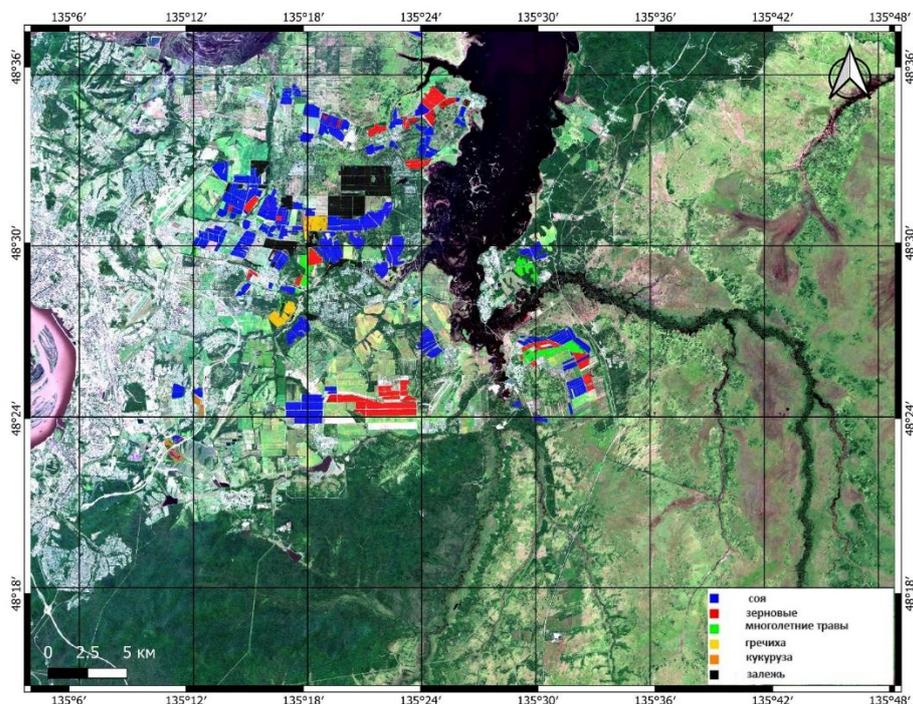


Рисунок 3.6 – Карта пахотных земель, построенная с использованием сезонных композитов NDVI и метода гистограммного градиентного бустинга (Хабаровский район, 2022 г.)

Точность распознавания посевов гречихи в 2023 г. оказалась меньше, чем в 2022 г., причём РА составила 0,76. Из 10 полей с гречихой проблемы с идентификацией наблюдались на двух. Результаты классификации на полигоне с гречихой (площадью 46 га), собранном из пяти сельскохозяйственных полей, представлены на рисунке 3.8. На этом поле 2 130 временных рядов были отнесены к классу «зерновые культуры», 1 768 рядов – к классу «соя», в то время как собственно гречихи выявлено всего 216 рядов. Неверная идентификация культуры может быть связана, во-первых, с проблемами развития посевов гречихи (максимум сдвинут на 32 неделю, что характерно скорее для посевов сои, затем идёт довольно быстрое снижение значений NDVI), во-вторых, с ростом сорной растительности в конце июня – начале июля (высокие значения и максимум в начале июля характерны для зерновых культур), в-третьих, со всходами сои и овса, которые высевались на этом участке в прошлые годы, отмеченными в ходе полевых наблюдений в июле, в начале периода роста гречихи.

соя	546861	456	135	659	1275	837
зерновые	556	138709	156	227	58	704
травы	172	3031	35000	32	34	416
гречиха	5193	2289	55	24843	23	205
кукуруза	10180	1340	15	17	19203	71
залежь	669	993	499	40	1	33491
	соя	зерновые	травы	гречиха	кукуруза	залежь

Рисунок 3.7 – Матрица несоответствий классификации с использованием сезонных рядов NDVI (2023 г.)



Рисунок 3.8 – Результат распознавания на проблемном поле с гречихой в 2023 г.

Увеличение количества рядов NDVI для посевов кукурузы в датасете 2023 г. привело к увеличению точности распознавания этой культуры ($F1 = 0,75$; $PA = 0,62$; $UA = 0,93$). Но, тем не менее, значения $F1$ и PA в 2023 г. недостаточно высокие. Также, как и в 2022 г., большое количество временных рядов NDVI для кукурузы при классификации попало в класс «soя» (10 180 рядов или 26,8 %). На уровне отдельных полей такие ложные срабатывания привели к тому, что из шести полей с кукурузой на трёх в качестве основной культуры была идентифицирована соя, ещё на двух полях доля временных рядов, отнесённых к классу «soя», превысила 25 %.

Всего на уровне полей на 509 из 520 полей в 2023 г. посевы культур и залежь были определены верно. Из 11 ошибок классификатора три пришлись на поля с посевами кукурузы, на которых в качестве культуры была определена соя. Одно из полей с посевами сои было определено как неиспользуемое, причём доля выявленной залежи на нём близка к 100 %. При рассмотрении усредненного графика сезонного хода NDVI на этом поле возникают сомнения в точности предоставлен-

ных по этому полю данных о севообороте – кривая сезонного хода схожа с эталонной кривой для залежи (рисунок 3.9). Скорее всего на этом поле сев либо не осуществлялся, либо поле было настолько засорено, что посевы сои на этом поле не детектировалась (отсутствует характерный пик и не заметна вспашка).

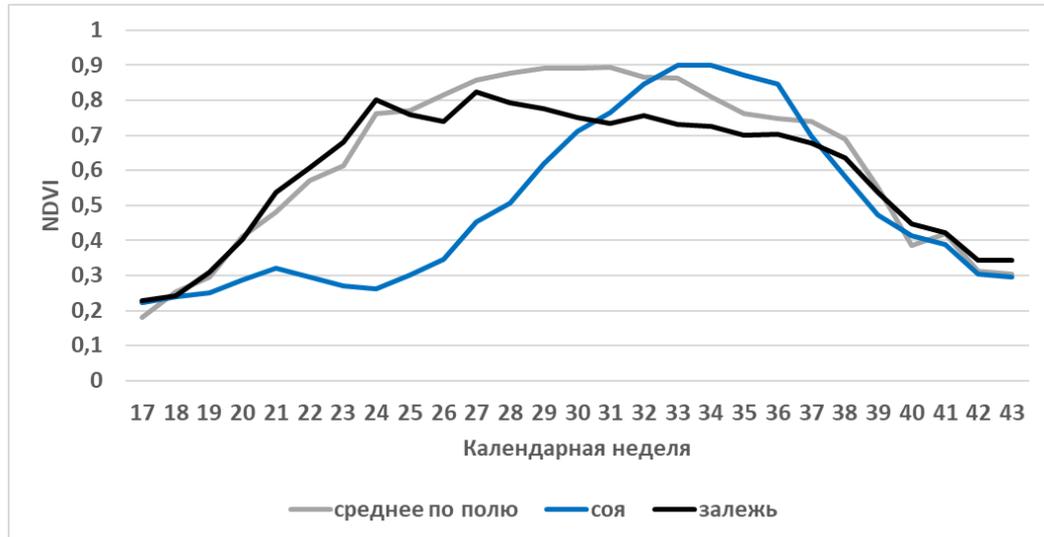


Рисунок 3.9 – Пример идентификация культуры на поле путём анализа сезонного хода NDVI

Три ошибки идентификации пришлось на поля с многолетними травами. Для данных полей характерен севооборот, включающий в себя как многолетние травы, так и зерновую культуру. Многолетние травы высеваются вместе с овсом: в первой половине первого года основной отклик даёт овёс, во второй половине сезона, а в особенности во второй и третий год, основное влияние на значения NDVI оказывает многолетняя трава (тимофеевка луговая). В случае, если овёс не был убран до конца первого года или убран не полностью, на второй и третий год наблюдаются его всходы, из-за чего определение культуры на этом поле усложняется, а поля могут идентифицироваться как поля с зерновыми культурами. Пример такого поля с многолетними травами второго года представлен на рисунке 3.10.

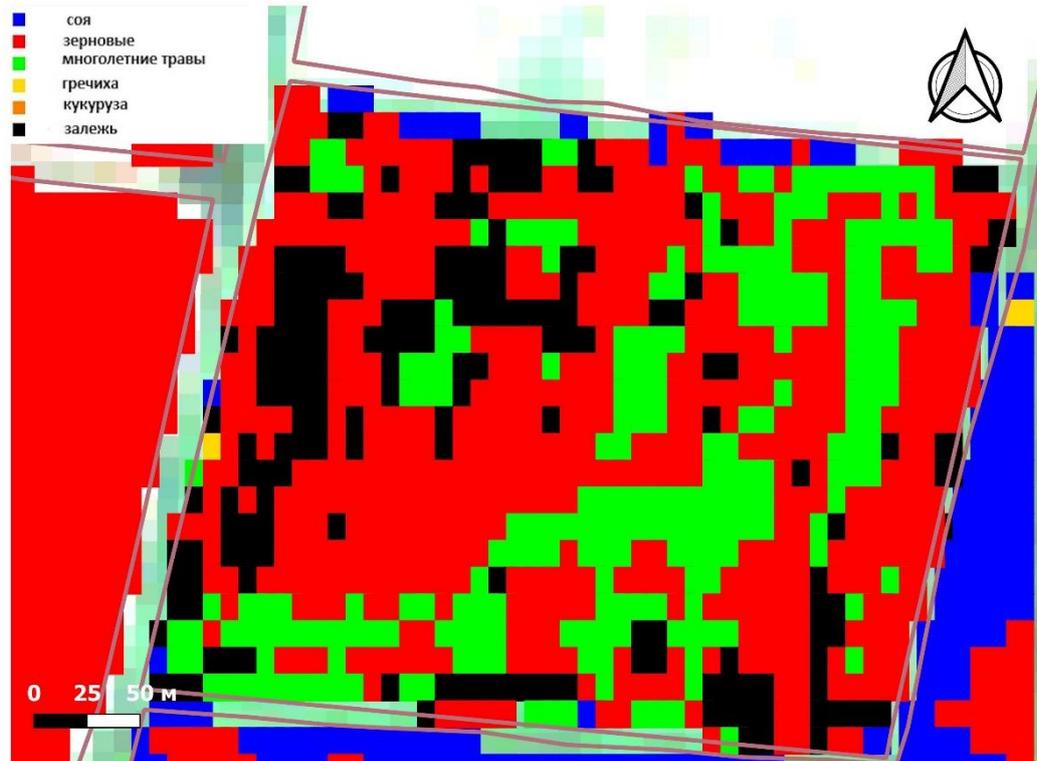


Рисунок 3.10 – Пример распознавания посевов на поле с овсом и многолетними травами в 2023 г.

На двух полях с посевами гречихи в качестве основной культуры была распознана соя, также соя была идентифицирована на одном из неиспользуемых полей. Ошибка идентификации на небольшом поле (количество пикселей сои и залежи на нём примерно равно) может говорить о том, что в один из предыдущих сельскохозяйственных сезонов там произрастала соя, которая дала в 2023 г. всходы, а залежь не является многолетней.

По результатам классификации были получены маски залежи, сои, многолетних трав, гречихи, зерновых культур и кукурузы на 2023 г. и сгенерирована карта пахотных земель для исследуемых полей Хабаровского района (рисунок 3.11).

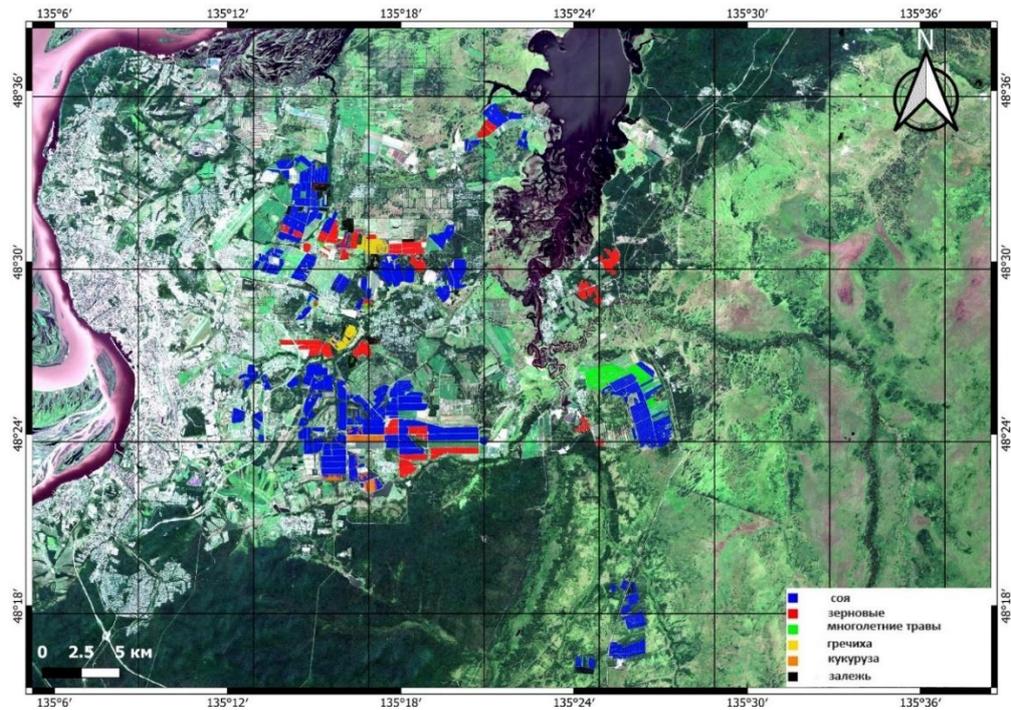


Рисунок 3.11 – Результаты распознавания посевов культур и неиспользуемой пашни (Хабаровский район, 2023 г.)

Значения метрик точности (РА, UA, F1) классификации для всех классов в 2021–2023 гг. приведены в таблице 3.1. Использование сезонных рядов NDVI позволяет с высокой точностью распознавать посевы сои (значения всех метрик превышают 0,95) и неиспользуемые пахотные земли (значения всех метрик не ниже 0,94). Также возможно эффективное распознавание посевов зерновых культур и многолетних трав: в годы, когда количество временных рядов было достаточным для анализа (в 2021 г. для обоих классов оно было менее 10 000), значения всех метрик для обоих классов превышали 0,9. Для гречихи в 2021 и 2022 гг. значения метрик точности не опускались ниже 0,92. Результаты распознавания кукурузы неоднозначны – большое количество временных рядов кукурузы распознаются как ряды сои. Из этого следует вывод, что для определения посевов кукурузы на сельскохозяйственных полях одних только рядов NDVI недостаточно. Однако, ряды NDVI этой культуры значительно отличаются от рядов NDVI заброшенных земель, трав, зерновых и гречихи. Посевные площади кукурузы в Хабаровском крае невелики, поэтому возможно разделение ее маски и маски сои по дополнительным данным наземных наблюдений.

Таблица 3.1 – Значения метрик точности классификации с использованием сезонных рядов NDVI

Год	Метрика	Залежь	Соя	Зерновые	Многолетние травы	Гречиха	Кукуруза
2021	PA	0,99	0,97	0,82	0,85	0,95	-*
	UA	0,98	0,99	0,89	0,65	0,97	-
	F1	0,99	0,98	0,86	0,74	0,96	-
2022	PA	0,97	0,98	0,96	0,93	0,92	0,55
	UA	0,95	0,97	0,96	0,95	0,95	0,8
	F1	0,96	0,98	0,96	0,94	0,94	0,65
2023	PA	0,94	0,99	0,99	0,9	0,76	0,62
	UA	0,94	0,97	0,94	0,98	0,96	0,93
	F1	0,94	0,98	0,97	0,94	0,85	0,75

* Сведения о полях отсутствуют

3.1.2 Результаты раннего распознавания посевов сельскохозяйственных культур и неиспользуемой пашни

Раннее распознавание посевов сельскохозяйственных культур в сочетании с анализом хода NDVI позволяет уже по ходу сезона оценивать посевные площади культур, качество работ в ходе посевной, состояние вегетации на полях, следовательно, и прогнозировать урожайность. По аналогии с использованием полных сезонных временных рядов NDVI была исследована возможность применения сокращенных временных рядов NDVI. В качестве временного периода для раннего распознавания культур использовалась 29 календарная неделя (третья декада июля), то есть каждый сокращенный временной ряд недельных композитов включал в себя 13 значений (с 17 по 29 неделю).

Общая точность классификации (кросс-валидация) по сокращенным временным рядам NDVI с применением гистограммного градиентного бустинга в 2021 г. составила 92,2 % (что на 5 % ниже, чем при использовании полных временных рядов). На рисунке 3.12 представлена матрица несоответствий классификации для сокращенных временных рядов в 2021 г. Для сои и залежи значения F1 составили 0,95. Довольно высокая точность достигнута при распознавании посевов гречихи ($F1_{\text{гречиха}} = 0,93$; $PA_{\text{гречиха}} = 0,91$; $UA_{\text{гречиха}} = 0,95$). 23 % рядов посевов зерновых культур попали в класс «залежь», при этом $PA_{\text{зерновые}}$ составила 0,55 (еще 496 рядов из 2 452 были отнесены к классам «соя» и «многолетние травы»). Этот результат

обусловлен, во-первых, недостаточным числом полей в выборке 2021 г, во-вторых, наличием проблемных участков на полях. Пользовательская точность для зерновых культур оказалась низкой ($UA_{\text{зерновые}} = 0,36$): в ходе классификации к классу «зерновые культуры» отнесено большое количество временных рядов посевов сои (903, или 25 %), многолетних трав (697, или 19 %) и залежи (599, или 16 %). Большая часть рядов NDVI для полей с посевами многолетних трав отнесена к наиболее представленным в выборке классам «залежь» (65 %) и «соя» (20 %). При этом в класс «многолетние травы» отнесено 4 015 рядов сои и 1 519 рядов залежи.

При распознавании на уровне полей на 90 полях из 96 (это на пять полей меньше, чем при использовании полных сезонных рядов), изучаемых в 2021 г, посевы культур (или их отсутствие) были идентифицированы верно (точность идентификации составила 93 %). Пять из шести ошибок идентификации связаны с распознаванием посевов многолетних трав: во-первых, культура на всех трех полях с многолетними травами была распознана неверно (два определены как неиспользуемые, ещё на одном выявлены посевы сои), во-вторых, на двух полях с посевами сои в качестве основной культуры были определены многолетние травы. Ещё одна ошибка распознавания произошла на одном из полей с посевами зерновых – на этом поле были распознаны ряды всех классов, но самым распространённым классом стал класс «залежь» (в случае использования полных временных рядов на этом поле также были обнаружены участки залежи, но площадь их была в три раза меньше, поэтому культура идентифицировалась верно).

соя	94481	903	4015	278	1656
зерновые	218	1350	278	33	573
травы	1449	697	337	41	4700
гречиха	143	132	35	16852	1455
залежь	572	599	1519	483	120233
	соя	зерновые	травы	гречиха	залежь

Рисунок 3.12 – Матрица несоответствий классификации с использованием сокращённых временных рядов NDVI в 2021 г.

В 2022 г. точность ранней классификации оказалась на 8 % меньше, чем для классификации по окончанию сезона, и составила 88,6 %. Матрица несоответствий для ранней классификации в 2022 г. с использованием сокращённых временных рядов представлена на рисунке 3.13. Значения F1 для сои и залежи немного не достигли отметки в 0,95 ($F1_{\text{соя}} = 0,94$; $F1_{\text{залежь}} = 0,93$). Несколько хуже получилось распознавание посевов зерновых культур и многолетних трав ($F1_{\text{зерновые}} = F1_{\text{травы}} = 0,81$). В случае зерновых культур произошла переоценка классификатором количества временных рядов, отнесённых к этому классу (на 9 %). На нескольких полях с посевами зерновых культур было обнаружено большое количество посевов сои (на трёх полях их доля превысила 25 %). При использовании полных сезонных временных рядов проблем на этих полях не наблюдается, поэтому, скорее всего, ошибки ранней классификации вызваны более поздней уборкой зерновых. По аналогии более поздний или частичный укос многолетних трав приводит к стабилизации значений NDVI и определению на некоторых полях большого количества участков залежи (таких рядов в 2022 г. оказалось 19 %).

Раннее распознавание посевов гречихи является нецелесообразным, так как её сев осуществляется в июле, поэтому практически весь сокращённый временной ряд характеризует естественную вегетацию до сева гречихи. На рисунке 3.14 видно, что с 17 по 26 неделю 2022 г. значения NDVI для полей с посевами гречихи и зерновых культур практически совпадали, а расхождения наблюдались только в три последние недели периода. Такая близость временных рядов привела к тому, что 15 975 рядов NDVI гречихи (61 % от общего числа рядов) попали в класс «зерновые культуры», точность производителя для гречихи оказалась меньше 0,35 ($PA_{\text{гречиха}} = 0,34$), а для зерновых культур снизилась до 0,78. Также значительной оказалась и ошибка ложного детектирования посевов гречихи: 4 526 временных рядов зерновых культур были отнесены к классу «гречиха» ($UA_{\text{гречиха}} = 0,62$).

soя	369792	9467	957	803	4731	2846
зерновые	10544	99073	90	4526	42	2921
травы	1157	258	24571	13	2	5948
гречиха	970	15975	7	8849	2	436
кукуруза	11558	15	4	8	3553	62
залежь	2249	2579	2904	178	107	126448
	soя	зерновые	травы	гречиха	кукуруза	залежь

Рисунок 3.13 – Матрица несоответствий классификации с использованием сокращённых временных рядов NDVI в 2022 г.

Подавляющее большинство временных рядов NDVI, относящихся к полям с кукурузой (76 %), при классификации попали в класс «soя». Обратная ошибка также достаточно велика: в результате классификации в классе «кукуруза» доля временных рядов посевов сои составила 56 %.

Точность распознавания на уровне полей по сокращённым рядам NDVI в 2022 г. составила 93 %. На 28 полях (при использовании полных временных рядов было допущено пять ошибок) из 405 культур была идентифицирована неверно: на 14 из 23 полей с посевами кукурузы в качестве основной культуры была определена соя, для четырех из семи полей с посевами гречихи более половины рядов попали в класс «зерновые культуры», четыре из 40 полей с посевами многолетних трав отнесены классификатором к неиспользуемым, пять ошибок идентификации наблюдалось на 208 полях с посевами сои (идентифицировались как поля с посевами зерновых культур), одна ошибка идентификации наблюдалась для неиспользуемого поля, где были выявлены посевы сои.



Рисунок 3.14 – Усреднённые временные ряды NDVI для посевов зерновых культур и гречихи, используемые для раннего распознавания культур (2022 г.)

В 2023 г. общая точность классификации изменилась незначительно по сравнению с 2022 г. и составила 88 % (матрица несоответствий приведена на рисунке 3.15). Распознавание для четырех из шести классов произошло успешно: $F1_{\text{соя}} = 0,92$; $F1_{\text{залежь}} = 0,9$; $F1_{\text{травы}} = 0,89$; $F1_{\text{зерновые}} = 0,84$. 1 818 рядов NDVI залежи (5 % от общего числа) попали в класс «многолетние травы», в то время как 1 864 временных ряда для посевов многолетних трав помечены классификатором как «залежь». Ошибочно классифицированные временные ряды локализованы на нескольких полях. Такая локализация может указывать на использование части заброшенных полей в качестве сенокосов (на одном из полей с точки зрения классификатора посевы многолетних трав занимали половину площади поля).

соя	508257	19389	602	3260	7900	752
зерновые	18562	119569	298	864	61	906
травы	667	594	34142	763	8	1864
гречиха	9594	5328	1486	15510	57	239
кукуруза	21264	184	9	10	8812	12
залежь	479	1015	1818	109	11	31238
	соя	зерновые	травы	гречиха	кукуруза	залежь

Рисунок 3.15 – Матрица несоответствий классификации с использованием сокращённых временных рядов NDVI в 2023 г.

Плавное снижение NDVI на некоторых полях с посевами многолетних трав (рисунок 3.16) указывает на их поздний укос, что привело к идентификации залежи. Минимальные значения NDVI наблюдались на 33–35 календарных неделях (около 0,3), что говорит о том, что полная уборка на поле произошла в конце августа – начале сентября, то есть во второй половине временного ряда. Ещё на одном поле с многолетними травами обнаружены временные ряды зерновых и залежи (схожая картина наблюдалась для этого поля и при использовании полных временных рядов), что указывает на неполную уборку зерновых годом ранее и наличие необрабатываемых участков в границах поля.

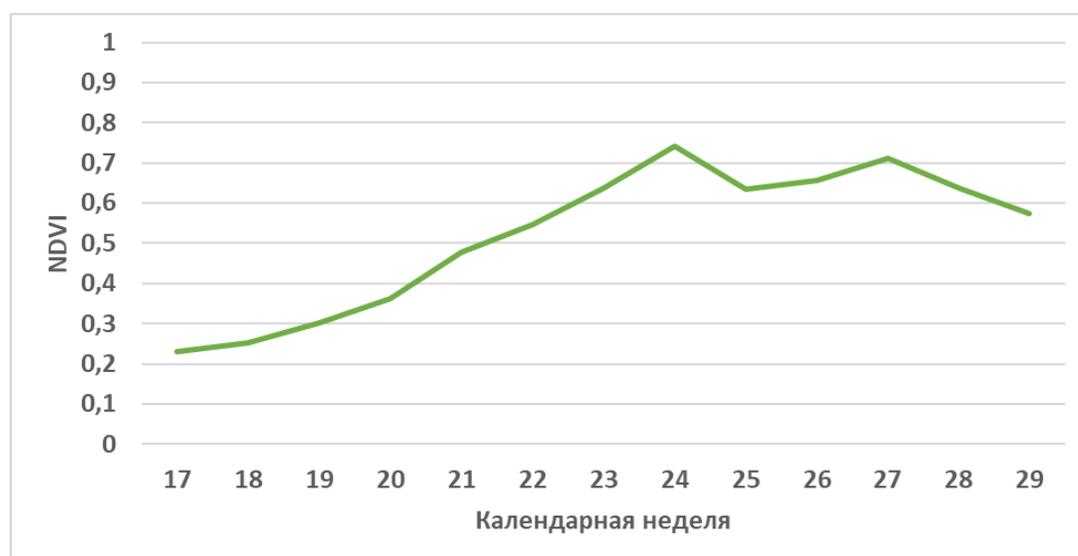


Рисунок 3.16 – Ход NDVI на поле с поздним укосом многолетних трав

На двух из 57 полей с посевами зерновых культур в качестве основной культуры идентифицирована соя. На рисунке 3.17 представлен усреднённый сокращённый ход NDVI для одного из таких полей. На графике видно, что уборка овса на этом поле осуществлялась после периода проведения ранней классификации, а поздний максимум более характерен для сои. Доля временных рядов зерновых, отнесённых классификатором к классу «соя», составляла 13 %.

Точность классификации оказалась недостаточной для распознавания посевов гречихи и кукурузы. Значение метрики F1 для посевов гречихи в 2023 г. составило 0,59 ($PA_{\text{гречиха}} = 0,48$; $UA_{\text{гречиха}} = 0,76$), значение F1 для посевов кукурузы

равнялось 0,37 ($PA_{\text{кукуруза}} = 0,29$; $UA_{\text{кукуруза}} = 0,52$). В обоих случаях UA значительно превышает PA , т. е. количество рядов NDVI этих классов на выходе классификатора оказывается значительно меньше, чем на его входе. В отличие от 2022 г., когда наибольшее количество временных рядов гречихи было отнесено классификатором к классу зерновых, в 2023 г. более распространены были случаи неверного распознавания в паре «гречиха» – «соя» (9 594 ряда, или 29,8 % рядов гречихи). Ошибки распознавания привели к тому, что на одном большом поле (46 га) с посевами гречихи в качестве основной культуры была идентифицирована соя, а на двух полях меньшей площади – зерновые культуры. Сев гречихи в обоих случаях осуществлялся на 27 календарной неделе. Разница в ходе NDVI между этими полями заключается исключительно в характере естественной вегетации до сева гречихи, зависящей от роста сорной растительности или всходов культуры-предшественника. Большинство временных рядов кукурузы в 2023 г., так же, как и в 2022 г., при классификации попало в класс «соя» – 21 264 ряда, или 70 %. При этом на всех шести полях с посевами кукурузы в качестве основной культуры была распознана соя. Несмотря на ошибки на отдельных участках, в целом количество ошибок на уровне полей оказалось меньше, чем в 2022 г. – 21 ошибка на 520 полей (точность 96 %, что всего на 2 % меньше, чем при использовании полных временных рядов).

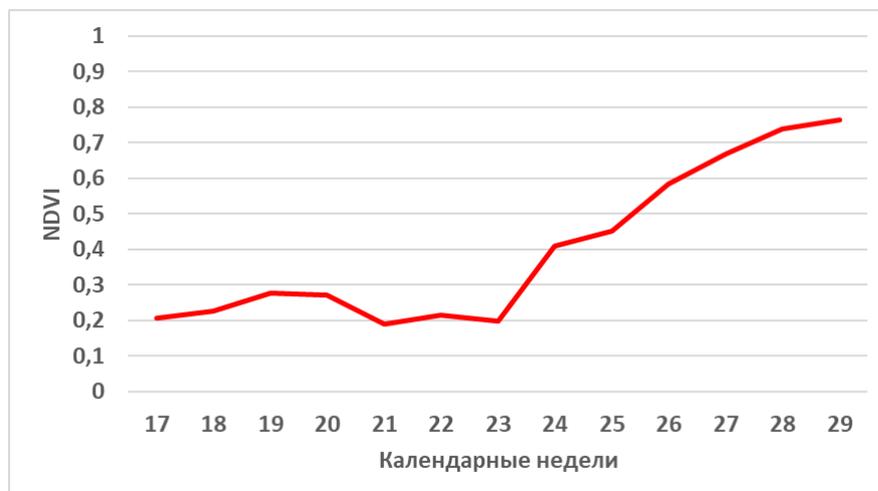


Рисунок 3.17 – Усреднённый ход NDVI для поля с поздней уборкой зерновых культур

В таблице 3.2 приведены значения всех метрик точности распознавания посевов сельскохозяйственных культур и неиспользуемой пашни по сокращённым временным рядам NDVI для трех лет исследования. Можно сделать вывод о том, что гистограммный градиентный бустинг может успешно использоваться для построения масок сои (F1 варьируется от 0,92 до 0,97) и заброшенных земель (F1 варьируется от 0,9 до 0,97) в середине сельскохозяйственного сезона.

Таблица 3.2 – Значения метрик точности ранней классификации с использованием сокращённых рядов NDVI

Год	Метрика	Залежь	Соя	Зерновые	Многолетние травы	Гречиха	Кукуруза
2021	PA	0,95	0,97	0,37	0,36	0,92	-*
	UA	0,98	0,97	0,61	0,47	0,96	-
	F1	0,97	0,97	0,46	0,41	0,94	-
2022	PA	0,94	0,95	0,85	0,77	0,34	0,23
	UA	0,91	0,93	0,78	0,86	0,62	0,42
	F1	0,93	0,94	0,81	0,81	0,44	0,30
2023	PA	0,9	0,94	0,85	0,9	0,48	0,29
	UA	0,89	0,91	0,82	0,89	0,76	0,52
	F1	0,9	0,92	0,84	0,89	0,59	0,37

В качестве других выделяемых классов при раннем распознавании культур в 2019–2020 гг. могут выступать «зерновые культуры» и «многолетние травы» (F1 в 2022–2023 гг. выше 0,8). Для распознавания посевов гречихи из-за позднего сева этой культуры необходимы более продолжительные временные ряды (использование полных временных рядов позволяет достичь точности в 90–95 %). Для успешного определения посевов кукурузы на сельскохозяйственных полях использования одного NDVI недостаточно.

3.2 Результаты автоматизированного картографирования земель сельскохозяйственного назначения Хабаровского района в 2019–2020 гг. по многолетним спутниковым данным

3.2.1 Использование результатов классификации для оценки площадей, занятых посевами сои. Сравнение полученных результатов с данными официальной статистики

При решении задачи восстановления сведений о севообороте в 2019–2020 гг. моделировалась ситуация ранней классификации пахотных земель на 29 календарной неделе (конец июля). Для обучения классификатора использовались сокращенные временные ряды NDVI за 2021–2023 гг. В качестве тестовых данных для модели, основанной на гистограммном градиентном бустинге, использовались сокращенные временные ряды за 2019–2020 гг. Распознавание велось в границах сельскохозяйственных полей, представленных в ЕФИС ЗСН. В качестве распознаваемых классов выступили «залежь», «соя», «зерновые культуры» и «многолетние травы».

Для оценки посевных площадей сои из полученной в результате распознавания маски удалялись ошибки классификации (например, поздно убранные зерновые, всходы сои на неиспользуемых полях). Для этого рассматривался результат классификации на уровне полей. Для полей, на которых в качестве основной культуры идентифицирована соя, в маску включались все пиксели, на которых были распознаны посеы сои. Для остальных полей, где выявленная площадь посевов сои превысила 20 %, проводился визуальный анализ связанности пикселей: если пиксели, помеченные как «соя» находились рядом, формируя участок внутри поля, полагалось, что на этом участке произрастает соя, и такой участок включался в результирующую маску. В случае, если доля выявленных классификатором посевов сои была ниже 20 %, или если пиксели сои были случайно распределены по полям других классов, такие пиксели не учитывались при расчёте площади. На рисунках 2.15 и 3.5 видно, что сезонный ход NDVI для посевов кукурузы и сои схож. По результатам классификации по сокращенным временным рядам в 2022 и 2023 гг.

(см. рисунки 3.12 и 3.15) видно, что разделить эти два класса не удалось. Близким к сезонному ходу NDVI сои и кукурузы является и сезонный ход картофеля, который из-за своей слабой представленности на полях района не рассматривался при построении карт пахотных земель в 2021–2023 гг. Количество полей и посевная площадь кукурузы и картофеля невелика, поэтому для удаления полей этих культур из маски сои использовались данные ЕФИС ЗСН о севообороте на полях Хабаровского района.

В результате работы классификатора, построенного на основе многолетних спутниковых наблюдений, из 2 581 196 рядов в 2019 г. 1 050 352 (40,7 %) были отнесены к классу «соя», 970 399 рядов (37,8 %) – к залежи, 475 121 ряд (18,4 %) – в класс «зерновые культуры», 85 234 ряда (3 %) – в класс «многолетние травы». Полученная карта земель сельскохозяйственного назначения для Хабаровского района в 2019 г. представлена на рисунке 3.18. Всего в 2019 г. в ЕФИС ЗСН в Хабаровском районе учтено 1 439 сельскохозяйственных полей общей площадью 28 550 га. Из этих земель 18 825 га отнесено к пашне, 5 980 га – к пастбищам и 3 745 га – к сенокосам.

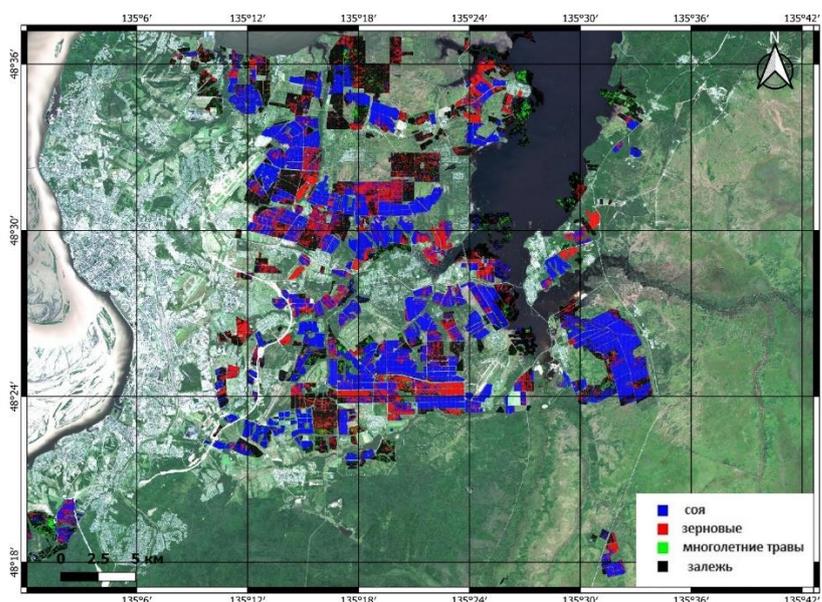


Рисунок 3.18 – Карта земель сельскохозяйственного назначения Хабаровского района в 2019 г. (в границах ЕФИС ЗСН)

В отчёте ЕФИС указано, что соя произрастает на 594 полях, площадь посевов составляет 13 504 га. В базе данных показателей муниципальных образований для Хабаровского района посевная площадь сои в хозяйствах сельхозорганизаций и фермерских (крестьянских) хозяйствах оценивалась в 13 044 га.

По результатам раннего распознавания посевов культур в 2019 г. выявлено 630 полей, где соя является основной культурой. После удаления восьми полей с посевами кукурузы и шести полей с посевами картофеля, для построения маски использовалось 616 полей (для сравнения, в ЕФИС содержались сведения о 594 полях с посевами сои). Количество временных рядов, отнесённых к классу «соя», составило 899 808. Учитывая размер пикселя снимка, посевная площадь на рассматриваемых полях составила около 9 000 га.

Ещё на 62 полях доля обнаруженных посевов сои превысила 20 %. Из них для 25 в ЕФИС ЗСН в качестве культуры указана соя, три поля отмечены как поля под паром, на остальных полях культура неизвестна.

При детальном анализе построенной карты видно, что на 12 полях посеvy сои занимают меньшую часть площади (20–30 %), в то время как большая часть площади поля не используется. Суммарная площадь участков на таких полях равна приблизительно 95 га. 23 поля с посевами сои сильно засорены в первой половине лета, поэтому при ранней классификации многие временные ряды этих полей попали в классы «залежь» и «зерновые культуры». Общая площадь этих полей составила 493 га, количество пикселей на них – 12 976 (общая площадь пикселей, включенных в маску сои составила 130 га). На рисунке 3.19 представлен пример поля, большая часть которого в сезоне 2019 г. не использовалась (в восточной части детектирована залежь и всходы посевов зерновых культур с предыдущих сельскохозяйственных сезонов). Автоматизированная классификация позволяет выявлять проблемные участки на полях и не учитывать их при оценке посевных площадей.

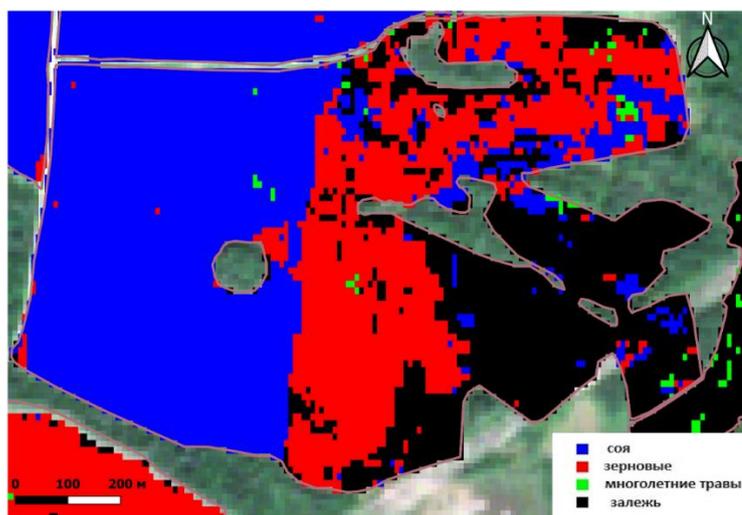


Рисунок 3.19 – Результат работы алгоритма распознавания на поле с некорректными границами (Хабаровский район, 2019 г.)

В 2020 г. в ходе автоматизированной классификации из 2 566 773 рядов, прошедших предварительную фильтрацию и включенных в датасет, 1 074 040 отнесены классификатором к классу «соя» (41,8 %), 970 764 ряда – к залежи (37,8 %), также выявлены 450 783 ряда зерновых культур (17,6 %) и 71 186 рядов многолетних трав (2,8 %). Удельная доля посевов культур в общей посевной площади изменилась по сравнению с 2019 г. незначительно (для сои увеличилась на 1,1 %, для зерновых и многолетних трав уменьшилась – на 0,8 и 0,2 %, соответственно).

В отчёте ЕФИС ЗСН о посевных площадях за 2020 г. указано, что в Хабаровском районе соя выращивалась на 614 полях общей площадью 13 040 га, при этом приведена посевная площадь – 12 611 га. В базе данных показателей муниципальных образований посевная площадь сои в хозяйствах сельхозорганизаций и фермерских (крестьянских) хозяйствах составила 10 730 га. Полученная в результате проведения классификации карта земель сельскохозяйственного назначения Хабаровского района на 2020 г. представлена на рисунке 3.20.

Автоматизированное раннее распознавание культур позволило выявить 636 полей, в границах которых класс «соя» преобладал над другими классами. Количество рядов NDVI, отнесённых к классу «соя» на этих полях составило 928 051 (более 85 % от всех выявленных посевов сои). Дополнительно из маски были уда-

лены 24 поля с кукурузой, пять полей с картофелем, три с капустой и один томатами. Таким образом, в маске сои осталось 878 547 пикселей 603 полей, площадь посевов сои – 8 785 га.

Из остальных полей были выделены только те, для которых количество временных рядов, отнесённых к классу «соя», превысило 20 %. Всего таких полей было обнаружено 175, что почти втрое больше, чем в 2019 г. По результатам визуального анализа снимков и построенной карты выявлено 16 сильно засоренных и заболоченных полей, на которых классификатор обнаружил 4 769 пикселей сои (48 га). Также обнаружено 53 поля, где посевы сои занимали менее половины от заявленной площади. Примеры полей, на разных участках которых в ходе одного сезона выращивались соя и зерновые, представлены на рисунке 3.21 (участки сева сои довольно легко определить визуально). Площадь обнаруженных на этих полях участков сои суммарно составляет 387 га.

Таким образом, суммарная оценка посевных площадей сои в Хабаровском районе в 2020 г. – 9 220 га. Эта площадь практически совпадает с вычисленной площадью посевов сои в 2019 г., при этом она меньше оценки Росстата на 14 % и значительно меньше оценки ЕФИС (почти на 30 %).

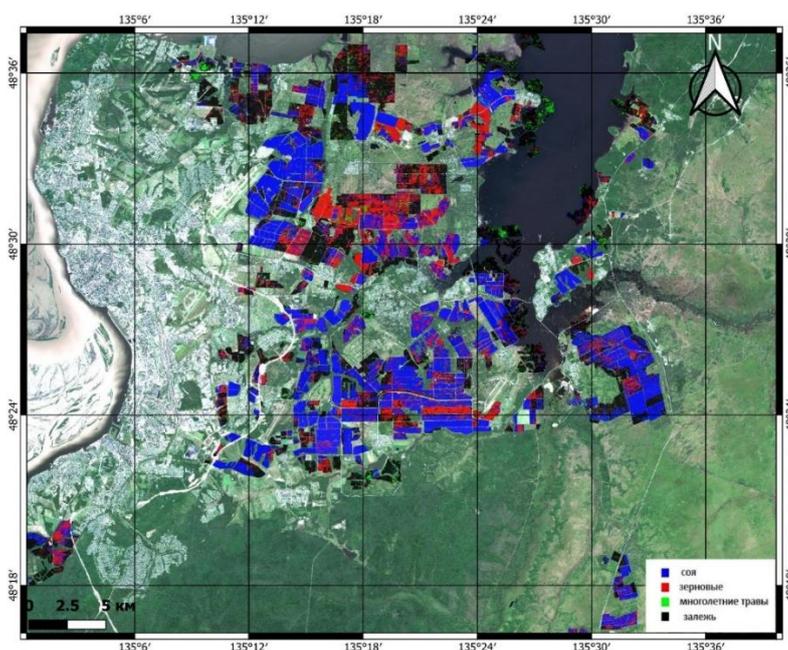


Рисунок 3.20 – Карта земель сельскохозяйственного назначения Хабаровского района в 2020 г.

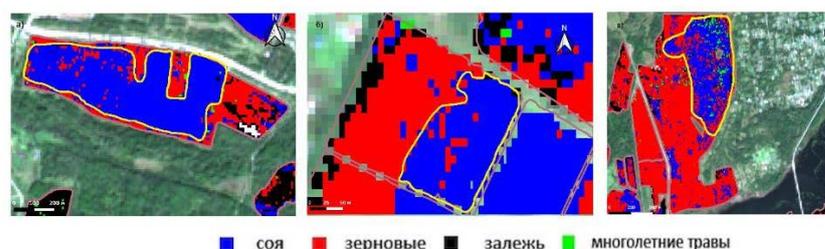


Рисунок 3.21 – Примеры полей, где производилось одновременное выращивание сои и зерновых культур (желтым цветом выделена часть поля, где предположительно выращивалась соя): а) посевы сои занимали около 70 % площади, б) площадь посевов сои и зерновых примерно равна, в) посевы сои занимали около 30 % площади

В таблице 3.3 представлены результаты оценки количества полей и посевных площадей, полученных по результатам построения маски сои, а также данные из ЕФИС ЗСН и Росстата. Полученные оценки посевных площадей сои в Хабаровском районе в 2019–2020 гг. оказались почти на треть меньше, чем оценки ЕФИС ЗСН. Завышение посевных площадей в ЕФИС ЗСН в первую очередь указывает на недостаточно актуализированные границы сельскохозяйственных полей. Также для части полей в системе отсутствует информация о типе использования и севообороте, а для некоторых полей с посевами различных культур (как на рисунке 3.21) не производится их разделение на отдельные участки. Именно поэтому классификатор выявил больше полей с соей, чем их указано в ЕФИС ЗСН, но их площадь оказалась значительно меньше. Оценки площади под посевами сои в данных Росстата значительно разнятся между годами. Особенно завышенной была оценка в 2019 г. (близка с оценкой ЕФИС ЗСН), в 2020 г. площадь посевов ближе к площади маски, созданной при автоматизированном распознавании земель.

Таблица 3.3 – Сравнение площади посевов сои в 2019–2020 гг. в Хабаровском районе по оценкам классификатора, ЕФИС и Росстата

Источник	Поля		Площадь, га	
	Год			
	2019	2020	2019	2020
Модель	651	672	9 225	9 220
ЕФИС ЗСН	594	614	13 515	13 040
Росстат	-	-	13 044	10 730

3.2.2 Использование результатов классификации для оценки площади неиспользуемых пахотных земель

В официальной статистике практически полностью отсутствует информация о площади неиспользуемых пахотных земель на уровне отдельных муниципальных районов. В ЕФИС ЗСН для части полей указано, что они не используются. Но в то же время, для многих полей отсутствует информация о типе использования и произрастаемой культуре. Чаще всего эти поля тоже являются залежью, но всё же в некоторых случаях на них могут быть посеяны культуры, а данные о севе не внесены в систему. В 3.2.1 было показано, что площадь полей с соей завышена на 30 % в основном именно за счёт неверных границ сельскохозяйственных полей (см. рисунок 3.19). Границы полей нуждаются в ежегодной корректировке. Они могут изменяться как в связи с недостатком посевного материала, так и с недостаточной мелиорацией и зарастанием сорной, кустарниковой и древесной растительностью. На рисунке 3.22 приведён пример изменения границ одного из полей в 2020 г. (площадь сократилась на 17 % по сравнению с 2019 г.).

Начальную маску заброшенных земель формируют пиксели, ряды NDVI которых попали в класс «залежь». Класс «залежь» весьма неоднороден: в него могут попадать как реально неиспользуемая пашня, так и пастбища с сенокосами. В ЕФИС ЗСН для полей указан вид угодий, что позволяет удалить из маски залежи пиксели полей, не относящихся к пашне.

Так, в 2019 г. классификатор на основе гистограммного градиентного бустинга отнёс к классу «залежь» 971 748 временных рядов. Из 971 748 пикселей, для которых были построены эти временные ряды, 206 774 пикселя относятся к пастбищам (в ЕФИС ЗСН в 2019 г. на территории Хабаровского района обозначено 299 пастбищ), ещё 251 744 пикселя находятся внутри сенокосов (117 сенокосов на территории района). Таким образом, 513 230 пикселей залежи относятся к неиспользуемой пашне, а её оценочная площадь в 2019 г. составляет 5 132 га.

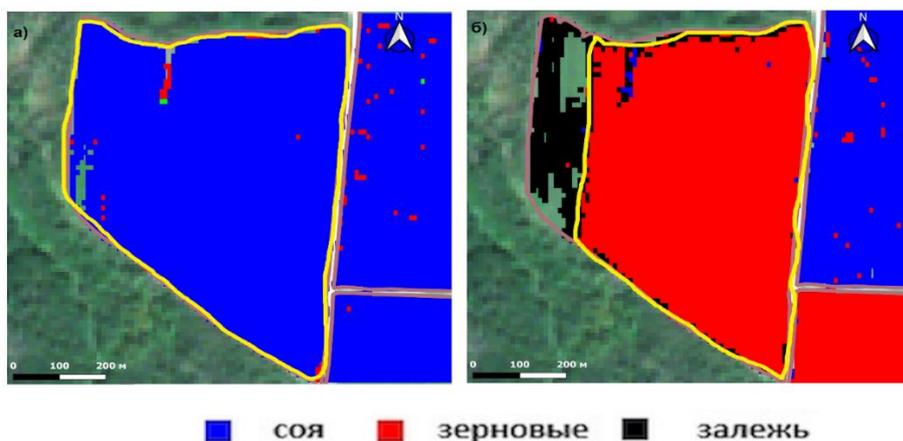


Рисунок 3.22 – Пример изменения границ поля (выделены жёлтым цветом):
 а) результат распознавания в 2019 г., б) результат распознавания в 2020 г.

В 2020 г. количество рядов, отнесённых к классу «залежь», изменилось незначительно. Всего классификатор присвоил такую метку 970 764 пикселям. 249 098 пикселей находились внутри границ пастбищ, ещё 255 767 – на землях, отнесённых к пастбищам. Итоговая маска залежи состоит из 465 899 пикселей, а площадь неиспользуемой пашни в 2020 г. оценивается в 4 659 га (почти на 10 % меньше, чем в 2019 г.).

В контексте мониторинга роста культур важно не только вычислять общую площадь залежи, но и оценивать степень используемости отдельных полей – выявлять проблемные участки, где возникают проблемы с севом, либо наблюдаются отклонения в ходе вегетации (единичные проблемные пиксели исключались из исследования ещё на стадии фильтрации временных рядов). Для наглядного представления степени используемости полей в Хабаровском районе были построены гистограммы, где по оси X были отложены диапазоны удельной доли выявленных пикселей залежи внутри поля; по оси Y указано количество полей, попавших в каждый диапазон (рисунки 3.23, 3.24).

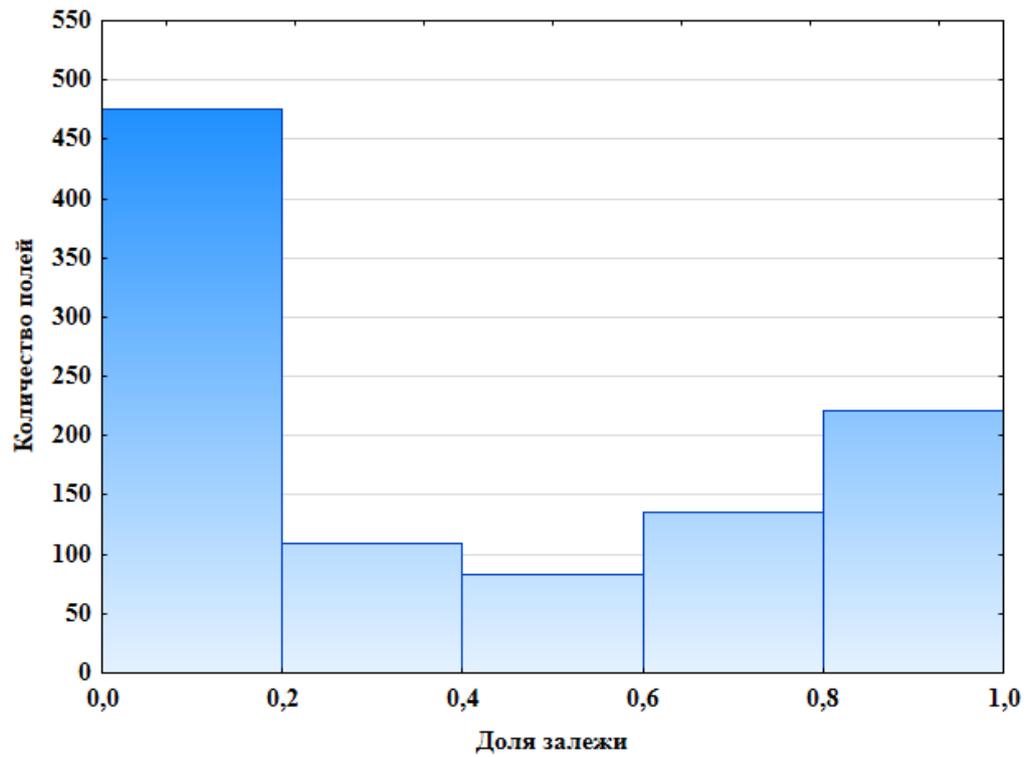


Рисунок 3.23 – Гистограмма распределения залежи по полям Хабаровского района в 2019 г.

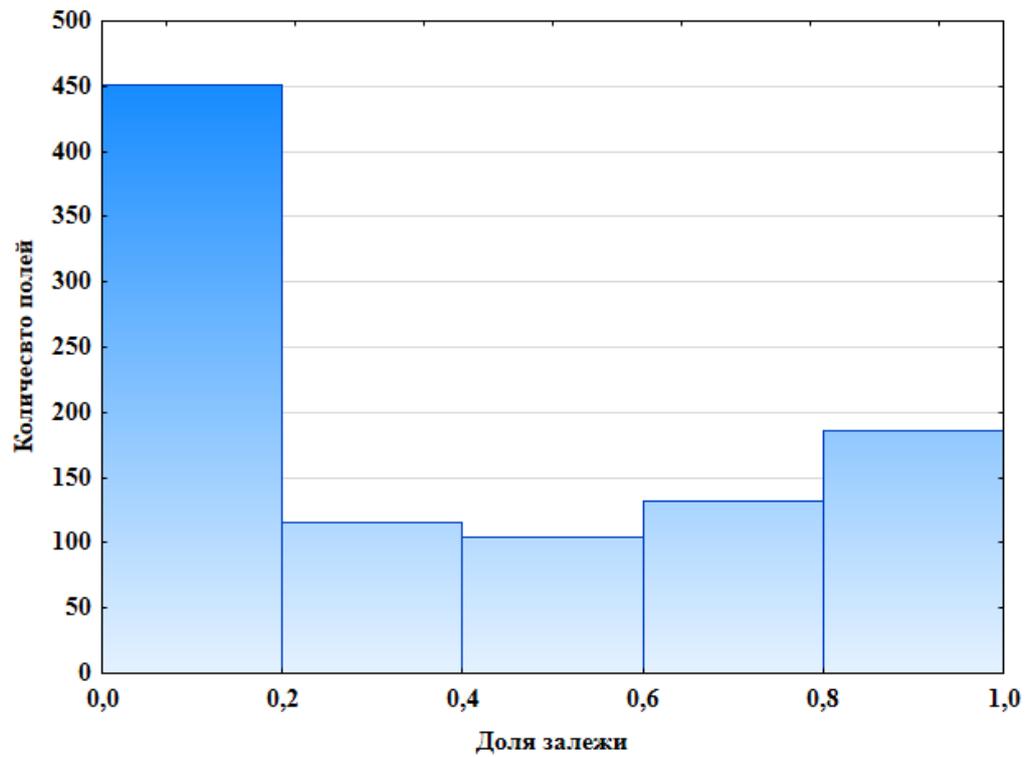


Рисунок 3.24 – Гистограмма распределения залежи на полях Хабаровского района в 2020 г.

Всего в ЕФИС ЗСН для Хабаровского района в 2019–2020 гг. содержится информация о 1 023 используемых под посевы культур полях. На рисунке 3.23 можно видеть, что в 2019 г. на 547 полях (более, чем 50 % от их общего количества) доля выявленных пикселей залежи превышает 20 %, на 400 полях (39 %) более половины площади поля не используется. 220 полей (21,5 %) можно отнести к заброшенным – на них доля пикселей залежи превысила 80 %. В 2020 г. доля пикселей залежи превысила 20 % на 536 полях (52 %), а на 377 полях (37 %) более половины поля не использовалось для сева культур.

Можно сделать вывод, что на территории Хабаровского района доля заброшенных пахотных земель в 2019 г. составила 30 % от общей площади пашни. В 2020 г. эта доля незначительно уменьшилась (до 27,5 %). Доля неиспользуемых полей сократилась с 21,5 до 18 %. Несмотря на незначительное улучшение ситуации в 2020 г., площадь неиспользуемой под посевы культур пашни превышает 25 % от общей площади пахотных земель, что подтверждает проблемы с большой площадью неиспользуемой пашни. Около 20 % полей являются заброшенными и могут служить резервом при введении новых земель в севооборот.

3.3 Использование рядов радиолокационного вегетационного индекса DpRVI для распознавания посевов сельскохозяйственных культур

Как уже было упомянуто выше, серьезным недостатком оптических данных является их зависимость от погодных условий. Данные SAR, не зависящие от освещения и облачных явлений, являются надежной альтернативой оптическим вегетационным индексам для решения задач сельскохозяйственного мониторинга. Сенсоры спутников Sentinel-1A/B позволяют наблюдать значительную часть Земли и получать данные двойной поляризации каждые 12 дней (каждые 6 дней при использовании обоих спутников). Этого достаточно для построения непрерывных временных рядов с достаточно большим количеством наблюдений за сезон.

Поэтому является целесообразным рассмотреть возможность распознавания основной культуры региона (сои), а также овса (самой распространённой зерно-

вой культур) и залежных земель на основе временных рядов для различных регионов Дальнего Востока.

3.3.1 Область исследования и исходные данные

В качестве области исследования выбраны муниципальные районы южной части Дальнего Востока России в бассейне реки Амур: Хабаровский район Хабаровского края и три района Амурской области: Архаринский, Ивановский и Октябрьский. Для расчета DpRVI снимки Sentinel-1 уровня обработки 1 SLC получены для Хабаровского района с одного трека (одна сцена), а для районов Амурской области – с двух треков (три сцены). Данные получены из распределенного архива Alaska Satellite Facility Distributed Active Archive Center [72], который содержит модифицированные данные Sentinel с 2015 г., обработанные Европейским космическим агентством. Временным периодом исследования являлся вегетационный сезон 2021 г. (с конца апреля по конец октября). Обработка радарных данных производилась с помощью инструмента Graph Processing Framework (GPF) на платформе ESA Sentinel Application Platform (SNAP) v.8.0 [95].

Радиолокационный индекс DpRVI рассчитывался по формуле (1.5). Размеченные сезонные ряды индекса DpRVI для пикселей сельскохозяйственных полей Хабаровского края разделены на обучающий (для построения модели) и тестовый (для оценки качества модели) наборы данных. Информация о севообороте, полученная в результате наземных наблюдений, дополнительно проверялась путем экспертного дешифрирования спутниковых снимков.

Ряды DpRVI для пикселей 80 полей, расположенных на территории Хабаровского края, разделены на три класса: «soя», «овес» и «залежь». Временные ряды для 40 полей использованы для построения модели, еще 40 участков – для оценки её точности. В таблице 3.4 представлена информация о количестве исследуемых полей и их площади. Доля залежных земель на исследуемых полях в Хабаровском крае превышала 35 %.

Таблица 3.4 – Число полей и площадь земель, временные ряды которых включены в обучающее и тестовое множество для Хабаровского края

Класс	Датасет			
	Обучающее множество		Тестовое множество	
	Поля	Площадь, га	Поля	Площадь, га
Залежь	10	299	10	109
Соя	10	292	10	115
Овёс	20	257	20	140
Всего	40	848	40	364

Часть территории Амурской области находилась в зоне подтопления в результате прохождения паводка. В результате визуального дешифрирования отобраны 29 полей, расположенных на территории Амурской области, не пострадавших от паводка. В качестве информации о севообороте использовались сведения из ЕФИС ЗСН, верифицированные в результате визуального дешифрирования. В таблице 3.5 приведена информация о количестве полей и площадях, включенных в выборку. Для пикселей этих полей построены временные ряды DrRVI.

Таблица 3.5 – Количество полей, исследуемых на территории Амурской области

Класс	Поля	Площадь, га
Залежь	10	769
Соя	9	775
Овёс	10	780
Всего	29	2 324

Несмотря на то, что значения DrRVI практически не зависят от атмосферных явлений, на некоторых участках полей, в некоторые даты, можно наблюдать аномальные значения этого индекса. Чтобы минимизировать зашумленность данных, проведена 2 σ -фильтрация обучающего датасета. После удаления аномальных рядов из выборки сформирован обучающий датасет, состоящий из 71 153 временных рядов. Тестовый датасет для Хабаровского края включал в себя 30 550 временных рядов. Тестовый датасет для Амурской области включал 203 120 временных рядов. Распределение рядов DrRVI между классами в датасетах представлено в таблице 3.6.

Таблица 3.6 – Количество временных рядов DpRVI в датасетах

Класс	Датасет		
	Обучающий	Тестовый, Хабаровский край	Тестовый, Амурская область
Залежь	20 442	9 181	70 736
Соя	25 436	9 756	68 621
Овёс	25 275	11 613	63 763
Всего	71 153	30 550	203 120

3.3.2 Машинное обучение и оценка точности

Для распознавания посевов сельскохозяйственных культур на основе DpRVI использовался алгоритм RF. Метод GridSearchCV из библиотеки scikit-learn [142] применялся для оптимизации гиперпараметров RF в ходе кросс-валидации. RF [80] – это метод машинного обучения, который использует оценки группы деревьев решений на различных подвыборках и принимает окончательное решение с помощью большинства голосов, чтобы повысить точность прогнозирования и контролировать переобучение. RF показал свою эффективность в задачах картографирования сельскохозяйственных угодий [67, 125, 151]. Его преимуществом является эффективность при работе с большими наборами входных данных с множеством признаков. Еще одним преимуществом RF является высокая точность и устойчивость к выбросам и шумам в данных [85]. Для оценки эффективности модели были рассчитаны метрики OA и F1. Также производилась оценка точности на уровне полей.

3.3.3 Анализ сезонного хода DpRVI для исследуемых классов

На рисунке 3.25 показан сезонный ход DpRVI для сои, овса и заброшенных полей в Хабаровском крае и Амурской области.

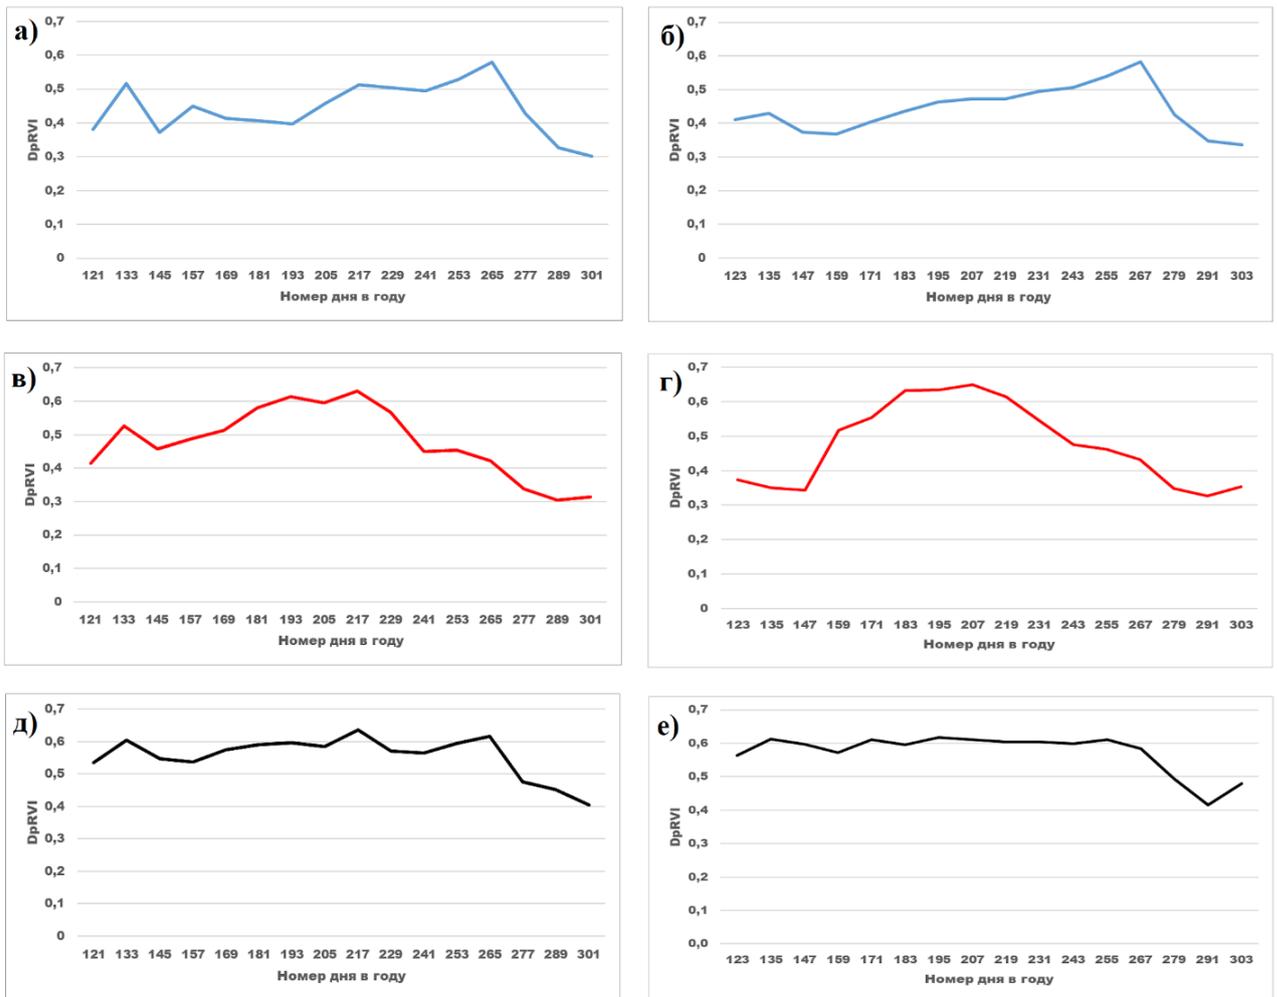


Рисунок 3.25 – Сезонный ход индекса DpRVI для: а) посевов сои в Хабаровском крае; б) посевов сои в Амурской области, в) посевов овса в Хабаровском крае; г) посевов овса в Амурской области; д) залежи в Хабаровском крае; е) залежи в Амурской области

На рисунках 3.25, а и 3.25, б видно, что сев сои проводился в период с середины мая по середину июня. Однако можно отметить, что в Хабаровском крае травяной покров на полях сформировался уже к началу июня. В Амурской области, в результате обработки почвы гербицидами, травяной покров не сформировался. По мере роста сои на полях значение DpRVI также увеличивалось. Максимум индекса был достигнут во второй половине сентября. С конца сентября значения DpRVI стали быстро снижаться.

Сев овса проводился в мае, однако в Хабаровском крае наблюдалось раннее увеличение значений DpRVI до сева культуры (рисунки 3.25, в и 3.25, г). Такой

рост может быть вызван не только быстрым развитием сорной растительности, но и неполной уборкой в предыдущем сельскохозяйственном сезоне – оставленные в почве зёрна дают ранние всходы. Максимум DpRVI для овса был достигнут в июле (в этот период индекс DpRVI стабилизируется). Время достижения максимума может значительно различаться – от начала июля в Ивановском районе Амурской области до конца июля в Хабаровском районе Хабаровского края. Значения максимума также значительно варьировали. На всей территории исследования уборка овса проводилась в конце июля-августе. Дальнейший рост DpRVI на некоторых полях мог быть вызван подсевом многолетних трав. График DpRVI для залежи не имеет выраженных пиков из-за отсутствия полевых работ в течение всего периода исследования (рисунки 3.25, *д* и 3.25, *е*). Тем не менее, различные природные и антропогенные явления могут приводить к вариациям роста травяного покрова на заброшенных пахотных землях.

3.3.4 Результаты распознавания посевов сельскохозяйственных культур и неиспользуемой пашни с использованием рядов DpRVI

Общая точность распознавания посевов сельскохозяйственных культур и неиспользуемой пашни с использованием рядов DpRVI для Хабаровского края составила 82 %. Значение F1 для сои превысило 0,9. Значения метрики F1 для овса и залежи составили 0,78. На рисунке 3.26 показана матрица несоответствий для классификации методом RF. Доля верно идентифицированных временных рядов составила 94 % для залежи, 97 % для сои и 68 % для овса. 31 % временных рядов овса отнесены RF к классу «залежь», а среди временных рядов, отнесенных классификатором к классу «залежи», доля посевов овса составила 27 %.

Залежь	8504	924	328
Соя	136	8664	381
Овёс	181	3559	7873
	Залежь	Соя	Овёс

Рисунок 3.26 – Матрица несоответствий для классификации методом RF на основе временных рядов DpRVI в Хабаровском крае

Обученный на временных рядах DpRVI для полей Хабаровского края классификатор был применен для распознавания посевов культур и неиспользуемой пашни на тестовых полях на территории муниципальных образований Амурской области. При этом ОА составила 83,1 %. На рисунке 3.27 показана матрица несоответствий для тестового набора в Амурской области. Доля верно классифицированных временных рядов составила 87 % для залежи и сои и 75 % для овса. Из-за региональных различий в сезонных рядах DpRVI 14 % посевов овса были идентифицированы как «залежь». Также возникли некоторые трудности при разделении посевов сои и овса – 11 % посевов овса были отнесены к классу «соя». Значение F1 для сои уменьшилось на 0,06 по сравнению с результатами для Хабаровского края, а для залежи и овса увеличилось, соответственно, на 0,06 и 0,01. Значения метрик точности для классификации на полях Хабаровского края и Амурской области представлены в таблице 3.7. Видно, что точность при использовании модели в другом регионе Дальнего Востока значительно не изменилась.

Общая точность идентификации в Амурской области на уровне полей составила 79 % (6 ошибок на 29 полей). Распознавание на основе DpRVI может применяться как для идентификации культур (рис. 3.28, а) и уточнения границ (рис. 3.28, б), так и для выявления залежных земель (рис. 3.28, г) и поиска неоднородностей (рис. 3.28, в).

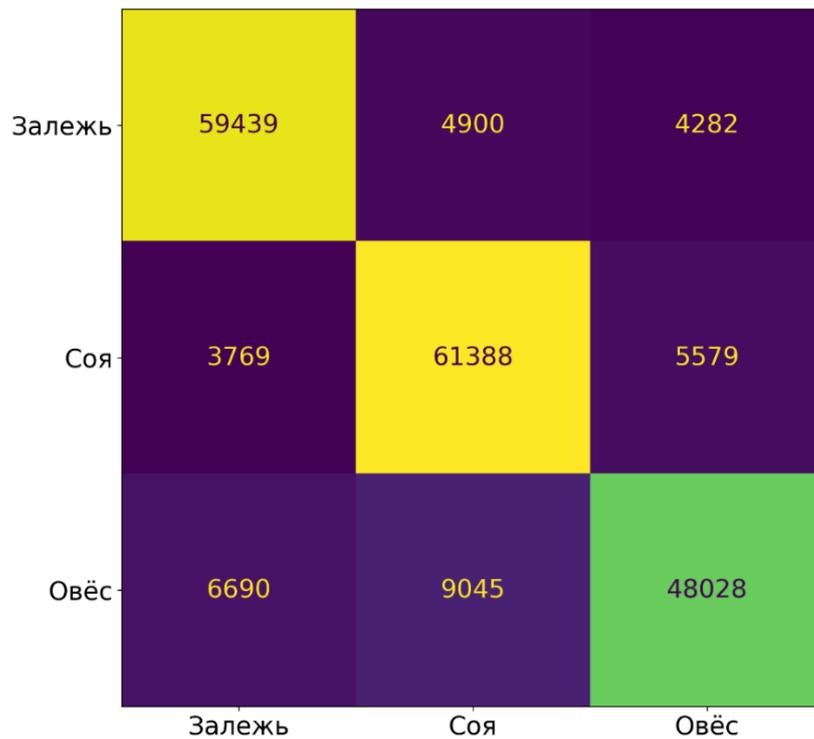


Рисунок 3.27 – Матрица несоответствий для классификации методом RF в Амурской области

Таблица 3.7 – Значения метрик точности классификации для полей Хабаровского края и Амурской области

Метрика	Регион	
	Хабаровский край	Амурская область
OA, %	82,0	83,1
F1 _{soя}	0,92	0,86
F1 _{овёс}	0,78	0,79
F1 _{залежь}	0,78	0,84

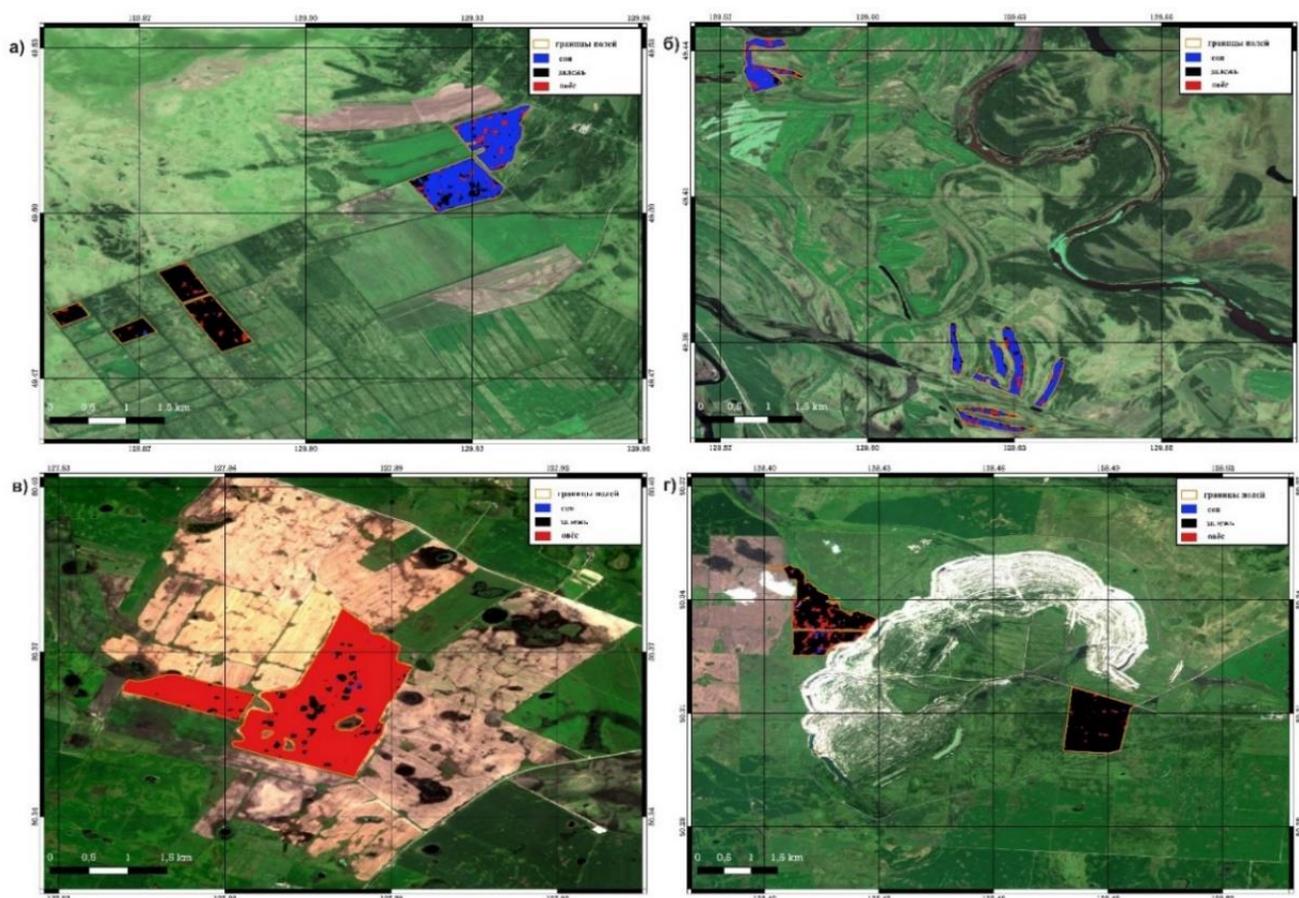


Рисунок 3.28 – Примеры работы алгоритма распознавания на основе временных рядов $DpRVI$ в Амурской области: а) поля с соей (выделены синим цветом) и залежь (выделена чёрным цветом); б) поля с соей, в) поля с овсом (обозначены красным цветом); г) неиспользуемая пашня

На рисунке 3.29 показан усреднённый сезонный ход $DpRVI$ для посевов овса в обучающем наборе (Хабаровский район), в Ивановском районе, где поля овса были распознаны правильно, и в Архаринском районе, где классификатор допустил ошибки. В Хабаровском и Ивановском районах сезонный ход $DpRVI$ на протяжении большей части сезона имел схожие тенденции (пик в июле и снижение значений после уборки культуры). Сезонный ход овса в Архаринском районе характеризовался низкими значениями $DpRVI$ летом и резким их увеличением осенью с формированием второго пика (по времени достижения, совпадающего с максимумом у сои), что привело к неправильной классификации. Наличие второго пика свидетельствует о наличии на поле подсева в виде многолетних трав.

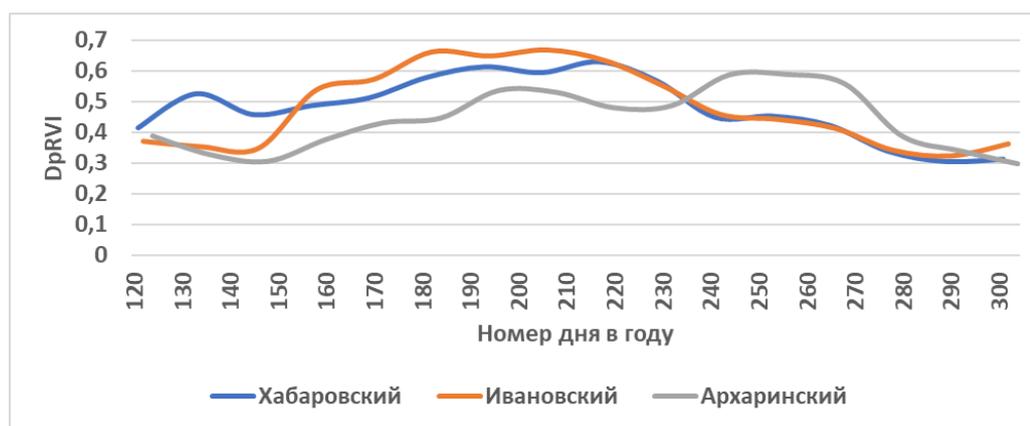


Рисунок 3.29 – Усреднённый сезонный ход DpRVI для класса «овёс» в обучающем наборе (Хабаровский район), в Ивановском и Архаринском районах

3.4 Выводы по третьему разделу

Разработанный алгоритм распознавания посевов сельскохозяйственных культур применен для сельскохозяйственных полей южной части Хабаровского края. Общая точность кросс-валидации на основе гистограммного градиентного бустинга с использованием сезонных временных рядов индекса NDVI в 2021 г. составила 97,3 %, в 2022 и 2023 гг. – 96,3 %. Общая точность классификации при решении задачи раннего распознавания оказалась на несколько процентов ниже: 92,2 % в 2021 г., 88,6 % в 2022 г., 88 % в 2023 г. Анализируя результаты исследования, можно сделать вывод о том, что сокращённые временные ряды NDVI могут успешно использоваться для построения масок сои (значение F1 варьировалось от 0,92 до 0,97) и заброшенных земель (значение F1 менялось от 0,9 до 0,97). Точность распознавания посевов зерновых культур и многолетних трав также находилась на достаточном для построения карт уровне (F1 в 2022 и 2023 гг. выше 0,8).

При восстановлении сведений о севообороте в 2019–2020 гг. моделировалась ситуация ранней классификации пахотных земель. Была получена оценка посевных площадей сои в Хабаровском районе – в оба исследуемые года она составляла около 9 220 га. Вычисленная площадь меньше оценки Росстата на 14 % и значительно меньше оценки ЕФИС (почти на 30 %). Оценочная площадь неиспользуемой пашни в Хабаровском районе составила 5 132 га в 2019 г. и 4 659 га в 2020 г.

Несмотря на незначительное снижение в 2020 г., площадь выявленной залежи превысила 25 % от общей площади пахотных земель.

Использование данных SAR (временных рядов DpRVI) позволило достичь общей точности 82 % при распознавании посевов сои, овса, а также залежных земель на территории Хабаровского края в 2021 г. Использование классификатора на основе метода RF, обученного на данных, собранных в Хабаровском крае, в Амурской области позволило распознать посевы сельскохозяйственных культур и неиспользуемую пашню с точностью 83,1 %. Несмотря на большую, по сравнению с моделями, использующими ряды NDVI, ошибку распознавания, использование модели на основе DpRVI может применяться при сильной разреженности временных рядов NDVI вследствие большого количества снимков с высоким процентом облачности.

4 ПРОГНОЗИРОВАНИЕ УРОЖАЙНОСТИ СОИ НА МУНИЦИПАЛЬНОМ УРОВНЕ С ИСПОЛЬЗОВАНИЕМ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Важной задачей мониторинга пахотных земель является создание эффективных моделей прогнозирования урожайности культур по ходу сельскохозяйственного сезона. Соя – одна из основных культур мирового агропромышленного комплекса [100]. На Дальнем Востоке России соя является основной возделываемой культурой; в 2018 г. на долю четырех регионов Дальнего Востока, имеющих общую границу с Китаем, пришлось более 50 % от общей площади посевов сои в России [62]. Поэтому задача прогнозирования урожайности сои в муниципальных районах Дальнего Востока является важной задачей для сельского хозяйства региона.

4.1 Прогнозирование урожайности сои с использованием максимального сезонного значения NDVI и метеорологических характеристик

Для построения регрессионной модели прогнозирования урожайности сои был выбран Хабаровский район Хабаровского края. В качестве спутниковых данных использовались недельные композиты NDVI за период с 15 по 42 календарные недели (первая половина апреля – вторая декада октября) 2010–2019 гг., полученные при помощи веб-сервиса Вега-Science [52]. Композитные изображения NDVI рассчитаны по данным каналов RED и NIR прибора MODIS, установленного на спутнике Terra (стандартные продукты MOD09 V006 [157]). Пространственное разрешение прибора MODIS составляет 250 м.

Также в сервисе Вега-Science присутствует и постоянно обновляется созданная в ИКИ РАН маска пахотных земель, построенная для всей территории страны [43]. Использование маски пахотных земель для прогнозирования урожайности отдельных культур возможно только в том случае, если основные культуры имеют схожие фенологические циклы. Поэтому представляется логичным построить модель сезонного временного ряда NDVI для пашни (с учетом соотношения основных выращиваемых культур). Использование одного и того же подхода для расче-

та индекса NDVI в модели и для пахотных земель всего муниципального района дает возможность использования данных дистанционного зондирования по маске пахотных земель для прогнозирования урожайности сои (так как соя является основной культурой в регионе) [137]. Для построения модели сезонного хода NDVI для пашни собраны сведения о севообороте для 57 полей ДВ НИИСХ (общей площадью более 1 500 га), расположенных на территории муниципального района, за период с 2014 по 2018 г. На рисунке 4.1 показан пример композитного изображения MODIS NDVI, маска пахотных земель для Хабаровского района и расположение земель ДВ НИИСХ.

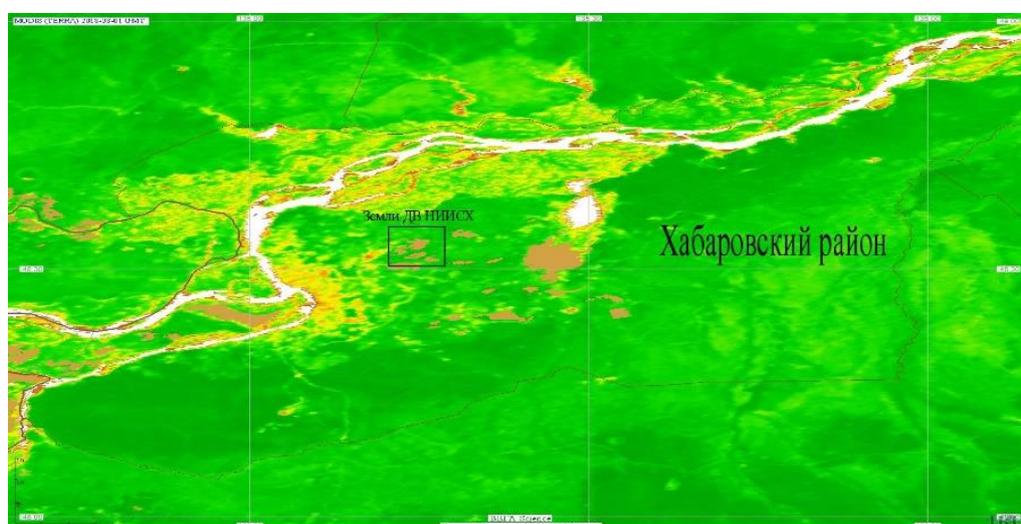


Рисунок 4.1 – Фрагмент композитного изображения NDVI для исследуемой области: коричневым цветом показана маска пахотных земель, прямоугольным контуром выделена область расположения земель ДВ НИИСХ

4.1.1 Построение модели сезонного хода NDVI для пашни

Для каждого из полей в системе Vega-Science были построены усреднённые временные ряды NDVI. Разнообразие культур на этих полях (широко представлены соя, многолетние травы, овёс и пшеница) позволяет как оценивать ход NDVI для отдельных культур, так и построить модель пашни с учётом соотношения культур в Хабаровском муниципальном районе.

Анализ динамики NDVI для посевов сои и зерновых культур (овес, яровая пшеница) показывает, что изменение значений этого показателя в течение сезона

соответствует плотности нормального распределения [58, 127]. Поэтому для характеристики кривых сезонного хода NDVI возможно использовать параметры функции Гаусса, полученные в ходе аппроксимации исходной кривой. Функция Гаусса имеет следующий вид:

$$F(i) = NDVI_{max} e^{\frac{-(i-b)^2}{2c^2}}, \quad (4.1)$$

где i – номер недели;

b и c – параметры функции.

При этом параметры функции описывают ход вегетации: параметр c характеризует календарную неделю, когда достигается максимум NDVI, а параметр b – ширину пика и, соответственно, количество недель с высокими значениями NDVI [161]. Для нахождения оптимальных параметров аппроксимации использовался алгоритм Левенберга – Марквардта [101]. Вычислительный алгоритм был реализован в виде программы на языке Python с использованием библиотеки `lmfit` [121], для построения графиков использовалась библиотека `matplotlib` [126]. Для оценки точности модели рассчитывалась средняя относительная ошибка (MAPE), рассчитываемая по формуле (2.2).

На рисунке 4.2 представлены усреднённые временные ряды NDVI для полей с посевами сои за 2014–2018 гг. и результаты их аппроксимации. Средние значения NDVI для посевов сои за каждую неделю рассчитаны как взвешенная сумма значений NDVI для всех полей с посевами сои (с учетом площади полей). На рисунке 4.2 видно, что выбранная для аппроксимации функция Гаусса хорошо приближает исходный ряд NDVI.

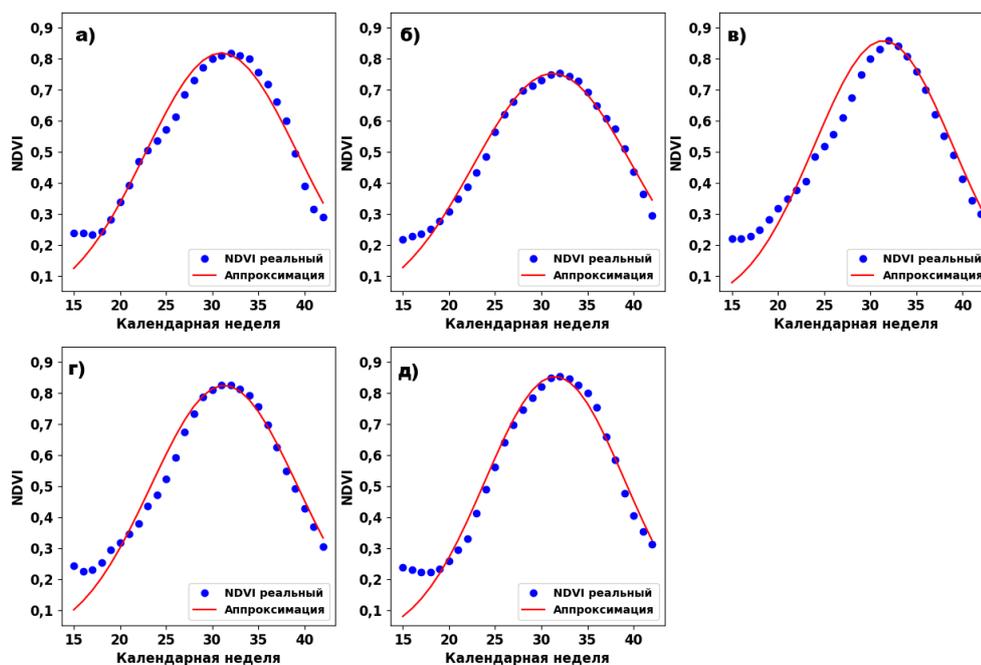


Рисунок 4.2 – Усреднённый временной ряд для опытных полей с посевами сои и график аппроксимирующей функции для: а) 2014; б) 2015; в) 2016; г) 2017; д) 2018 г.

Значения параметра c в исследуемые годы варьировали от 7,5 до 8,7, а параметра b – от 31,0 до 31,5 (представлены в таблице 4.1). Примечательно, что 2015 г. характеризуется максимальной шириной пика и наименьшим максимумом. Напротив, в 2016 и 2018 гг. максимальные значения NDVI, соответственно, составили 0,86 и 0,85, а значения b были минимальными – 7,5 и 7,6. Точность аппроксимации в 2014 и 2015 гг. составила соответственно 8,5 и 6,0 %, в 2016 г. – 13,9 %, а в 2017 и 2018 гг. – 10,2 и 10,9 %.

Для моделирования NDVI пахотных земель использовались ряды для 21 поля с посевами сои, 14 полей с посевами овса, семи полей с посевами пшеницы и 15 полей с посевами многолетних трав за 2018 г. Значения NDVI для пашни были получены путём расчёта взвешенной суммы (с учётом соотношения посевных площадей в Хабаровском районе) значений NDVI для этих культур. Значения параметра c для модели пашни составило 9,2. Увеличение параметра c (по сравнению с NDVI для посевов сои) объяснимо, так как разные культуры характеризуются разными максимальными значениями NDVI и продолжительностью вегета-

ционного периода, что, соответственно, способствует расширению пика вегетации и снижению максимума NDVI относительно ведущей культуры, при этом общая площадь под кривой примерно совпадает с аналогичной площадью для посевов сои. MAPE аппроксимации для пашни оказалась менее 7 %.

Таблица 4.1 – Параметры кривых сезонного хода NDVI, значения максимума NDVI и ошибки аппроксимации для полей с посевами сои в 2014–2018 гг.

Показатель	Год				
	2014	2015	2016	2017	2018
<i>c</i>	8,2	8,7	7,5	8,0	7,6
<i>b</i>	31,0	31,3	31,4	31,4	31,5
<i>NDVI_{max}</i>	0,82	0,75	0,86	0,83	0,85
MAPE, %	8,5	6,0	13,9	10,2	10,9

На рисунке 4.3, *a* показан сезонный ход NDVI для модели, учитывающей структуру пашни в Хабаровском районе, и результат его аппроксимации функцией Гаусса. На рисунке 4.3, *б* приведён усреднённый временной ряд NDVI для пахотных земель Хабаровского района за 2014–2018 гг., построенный по маске пахотных земель, а также график аппроксимирующей функции. Максимальное значение NDVI для маски пахотных земель достигается раньше, чем максимум аппроксимирующей функции. С 2014 по 2018 г. максимум NDVI для маски пахотных земель приходился на 26–30 календарные недели (раньше в 2014, 2015 и 2018 г. и позже в 2016 и 2017 г.). Средний максимум NDVI за 2014–2018 гг. пришёлся на 28 календарную неделю. Значения *b* в 2014, 2016 и 2018 гг. находились на уровне 29,8–29,9, в 2017 г. – 29,4, а в 2015 г. – 30,5. Параметр *c* изменялся от 10,1 до 10,4. Усреднённые за 5 лет расчетные параметры составили, соответственно, 29,9 и 10,3. Ошибка аппроксимации варьировала от 3,9 % в 2017 г. до 7,7 % в 2014 г. Максимальное значение NDVI для маски пахотных земель оказалось значительно меньше, чем для модели пашни и для полей с посевами сои и варьировало от 0,71 в 2016 г. до 0,76 в 2017 г. Усредненное (2014–2018 гг.) максимальное значение NDVI составило 0,73. Снижение значений NDVI и смещение пика на графике на более ранние даты можно объяснить ошибками при формировании

маски пахотных земель, а именно включением в маску части неиспользуемых полей и лугов. В таблице 4.2 представлены значения параметров аппроксимирующей функции, максимумы NDVI и ошибки аппроксимации для модели и маски пашни.

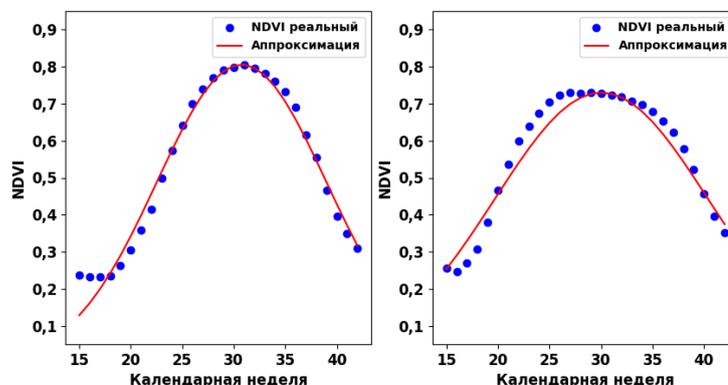


Рисунок 4.3 – Сезонный ход NDVI и результат его аппроксимации: а) для модели пашни в 2018 г.; б) усреднённый по маске пахотных земель за 2014–2018 гг.

Проведённый анализ временных рядов показал, что максимальные значения NDVI (2014–2018 гг.) для пашни в Хабаровском районе сильно коррелируют с максимальными значениями NDVI для полей с посевами сои ($\rho = 0,73$). На рисунке 4.4 представлен график сезонного хода NDVI для пахотных земель и результат его аппроксимации. Аппроксимация осуществлялась для сезонного хода NDVI в 2019 г. двумя способами: по значениям временного ряда и с использованием параметров аппроксимирующей функции, полученных по усредненным значениям NDVI за 2014–2018 гг. Максимальное значение NDVI для пахотных земель в 2019 г. было достигнуто на 29 календарной неделе и составило 0,73. Значение b составило 29,6, а значение c составило 8,9, MAPE равнялась 7,3 %. При аппроксимации усреднённого за 5 лет временного ряда значения параметров составили соответственно 29,9 и 10,3. При этом MAPE увеличилась до 12,6 %, а смоделированное максимальное значение NDVI составило 0,73. Отклонение предсказанного максимума от наблюдаемого составило 0,4 %. Таким образом, усреднённые временные ряды NDVI за предыдущие годы могут использоваться для прогнозирования максимума NDVI по ходу текущего сезона.

Таблица 4.2 – Значения параметров аппроксимации, максимумы NDVI и ошибки аппроксимации для модели пашни и для маски пашни

Показатель	Сезонный ход NDVI		
	Модель, 2018	Маска, 2018	Маска, 2014–2018
c	9,2	10,1	10,3
b	30,4	29,9	29,9
$NDVI_{max}$	0,81	0,73	0,73
MAPE, %	6,6	6,9	6,5

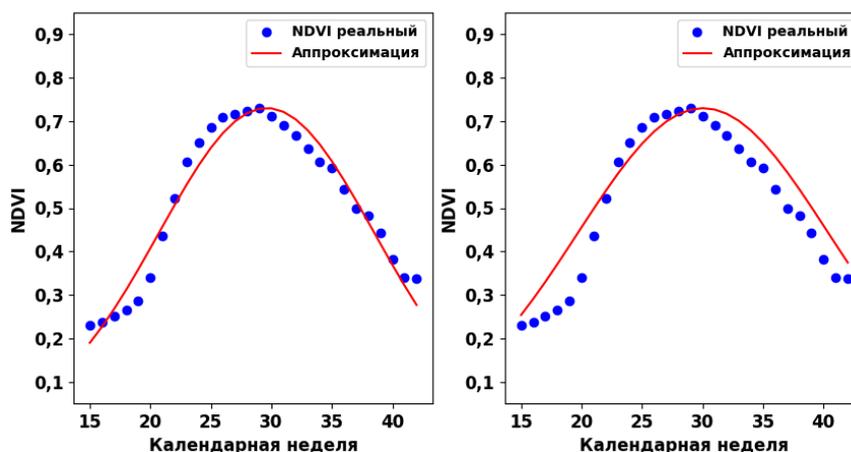


Рисунок 4.4 – График сезонного хода NDVI для Хабаровского района в 2019 г. и графики аппроксимации: а) построенные по значениям временного ряда; б) построенные по усреднённым значениям NDVI за 2014–2018 гг.

4.1.2 Построение регрессионной модели для прогнозирования урожайности на районном уровне

Для прогнозирования урожайности сои в Хабаровском районе была разработана линейная регрессионная модель. Построение модели осуществлялось в аналитическом программном пакете Statistica [146] методом обратной пошаговой регрессии. В качестве зависимой переменной рассматривалась урожайность сои в Хабаровском районе по данным Росстата [5] (за период с 2010 по 2018 г.). В качестве независимых переменных – значения максимума вегетации по маске пахотных земель района и метеорологические характеристики, полученные из сервиса Vega-Science (усреднённые данные реанализа в двух узлах сетки $0,5^\circ \times 0,5^\circ$

(с координатами 48°30' с.ш., 135°00' в.д. и 48°30' с.ш., 135°30' в.д.), расположенных на территории исследуемого района). Прогнозирование осуществлялось на 30 календарной неделе, по достижении максимума NDVI для пахотных земель. Расчёт метеорологических данных выполнялся за период с 15 календарной недели до недели прогнозирования.

Таким образом, всего для построения модели рассматривались один зависимый и шесть независимых показателей:

y – усреднённая оценка урожайности сои по муниципалитету, т/га;

x_1 – максимальное значение NDVI по маске пахотных земель муниципалитета;

x_2 – гидротермический коэффициент Селянинова, рассчитанный по формуле:

$$\text{ГТК} = \frac{10 \sum P_{T>10^\circ}}{\sum T_{>10^\circ}}, \quad (4.2)$$

где $\sum P_{T>10^\circ}$ – сумма осадков (мм);

$\sum T_{>10^\circ}$ – сумма среднесуточных температур воздуха. При расчёте учитываются только дни с активной вегетацией (со среднесуточной температурой выше 10 °С);

x_3 – количество дней с активной вегетацией;

x_4 – сумма среднесуточных температур верхнего слоя почвы (глубина до 10 см), °С;

x_5 – средняя влажность верхнего слоя почвы (глубина до 10 см), %;

x_6 – показатель фотосинтетически активной радиации (ГДж*м²), рассчитывается по формуле:

$$\text{ФАР} = 0.48 \cdot SF \cdot 10^{-9}, \quad (4.3)$$

где SF – суммарная нисходящая коротковолновая радиация.

В итоге многофакторная регрессионная модель имеет следующий вид:

$$y = b + a_1 x_1 + a_2 x_2 + a_3 x_3 + a_4 x_4 + a_5 x_5 + a_6 x_6. \quad (4.4)$$

Для оценки точности прогнозирования урожайности производился расчёт МАРЕ. В таблице 4.3 представлены значения урожайности и всех предикторов регрессионной модели за 2010–2018 гг. Урожайность сои – достаточно изменчивый

показатель, коэффициент вариации которого составил 17 %. Минимальная урожайность наблюдалась в 2016 г. (1,01 т/га), а максимальная – в 2018 г. (1,67 т/га). Независимая переменная x_2 имела наибольший коэффициент вариации (20,8 %). Максимальные значения NDVI имели наименьшую вариабельность – 2,4 %, в то время как вариабельность x_3 , x_4 и x_5 составляла 6–7 %. В целом, 2010, 2011, 2013 и 2015–2017 гг. характеризовались поздним началом вегетационного периода (x_3 варьировал от 71 до 75 дней). Для 2012, 2014 и 2018 г. x_3 изменялось от 82 до 84 дней. Высокие значения ФАР наблюдались в 2014 и 2017–2018 гг. и менялись от 1,13 до 1,16 ГДж*м². Наибольшие значения показателей, характеризующих влажность, наблюдались в 2015 г. Средняя относительная влажность почвы (x_5) составила 34,8 %, а ГТК (x_2) – 3,07.

Корреляционный анализ предикторов выявил, что ряд показателей связаны друг с другом. Это позволило сократить количество независимых переменных в модели. В таблице 4.4 приведены коэффициенты ранговой корреляции Кендалла для зависимых и независимых переменных регрессионной модели.

Достаточно высокое значение коэффициента корреляции наблюдалось между показателями x_3 и x_4 ($\tau = 0,61$), а также x_5 и x_6 ($\tau = -0,55$). ФАР сильнее коррелирует с урожайностью, чем влажность почвы, поэтому показатель x_5 решено не включать в модель. Из-за значительной корреляции с количеством дней вегетации исключена из модели температура почвы. Также можно предварительно охарактеризовать влияние показателей на урожайность сои. Так, максимальное значение NDVI, количество дней вегетации, суммарная температура почвы и ФАР положительно влияют на урожайность. И наоборот, средняя влажность почвы и ГТК влияют на урожайность сои отрицательно. Переменные x_4 и x_5 были исключены в ходе корреляционного анализа, а переменные x_2 (ГТК) и x_6 (ФАР) были автоматически исключены при пошаговом построении регрессионной модели как незначимые показатели ($p > 0,05$).

Таблица 4.3 – Урожайность сои, максимум NDVI и значения метеорологических характеристик в 2010–2018 гг.

Год	Переменная						
	<i>y</i>	<i>x</i> ₁	<i>x</i> ₂	<i>x</i> ₃	<i>x</i> ₄	<i>x</i> ₅	<i>x</i> ₆
2010	1,13	0,73	1,90	71,0	1 398,2	31,3	1,09
2011	1,19	0,74	3,03	71,0	1 325,9	31,5	1,09
2012	1,29	0,70	2,03	84,0	1 524,7	31,7	1,09
2013	1,50	0,73	2,45	72,0	1 402,0	33,9	1,06
2014	1,47	0,72	2,58	82,0	1 568,1	30,7	1,13
2015	1,19	0,74	3,07	73,0	1 318,0	34,8	1,07
2016	1,01	0,71	2,55	72,0	1 379,6	31,0	1,05
2017	1,58	0,76	1,56	75,0	1 477,4	29,3	1,16
2018	1,67	0,73	2,52	82,0	1 506,2	28,9	1,14
\bar{x}	1,34	0,73	2,41	75,8	1 433,8	31,2	1,10
σ	0,23	0,02	0,50	5,3	84,1	1,9	0,04
V, %	17,0	2,4	20,8	7,0	5,9	6,2	3,2
$\Delta\bar{x}$	0,17	0,01	0,39	4,1	64,7	1,5	0,03
min	1,01	0,70	1,56	71,0	1 318,0	28,9	1,05
max	1,67	0,76	3,07	84,0	1 568,1	34,8	1,16

В результате уравнение множественной регрессии, характеризующее зависимость урожайности сои в Хабаровском районе от включенных в модель показателей, построенное по данным 2010–2018 гг., имеет следующий вид:

$$y = -8.24 + 9.39x_1 + 0.036x_3, \quad (4.5)$$

то есть включает в себя только два предиктора: максимум NDVI и количество дней вегетации. Коэффициент детерминации модели (R^2) составил 0,72. Все коэффициенты уравнения регрессии значимы ($p < 0,05$).

Таблица 4.4 – Корреляционная матрица для исследуемых переменных (курсивом выделены значения коэффициента корреляции более 0,5)

	<i>y</i>	<i>x</i> ₁	<i>x</i> ₂	<i>x</i> ₃	<i>x</i> ₄	<i>x</i> ₅	<i>x</i> ₆
<i>y</i>	-	0,24	-0,20	0,42	0,4	-0,25	0,53
<i>x</i> ₁	0,24	-	0,06	-0,28	-0,35	0,01	0,28
<i>x</i> ₂	-0,20	0,06	-	-0,09	-0,33	0,28	-0,32
<i>x</i> ₃	0,42	-0,28	-0,09	-	0,61	-0,26	0,27
<i>x</i> ₄	0,4	-0,35	-0,33	0,61	-	-0,39	0,37
<i>x</i> ₅	-0,25	0,01	0,28	-0,26	-0,39	-	-0,55
<i>x</i> ₆	0,53	0,28	-0,32	0,27	0,37	-0,55	-

Анализ результатов применения разработанной регрессионной модели показал, что прогнозные значения для большинства наблюдаемых лет находятся в пределах доверительного интервала ($\gamma = 0,95$) для фактической урожайности сои. Наибольшее отклонение наблюдалось в 2013 г., что, скорее всего, связано с неточной оценкой урожайности сои в Хабаровском районе, вызванной крупнейшим за всю историю наблюдений паводком на реке Амур. В результате наводнения пострадали 16 тысяч га сельскохозяйственных угодий Хабаровского края, в том числе земли Большого Уссурийского острова (затоплено около 90 % территории острова).

С помощью регрессионной модели был произведён прогноз урожайности сои в Хабаровском районе на 2019 г. Ошибка прогнозирования составила 0,13 т/га, или 6,3 %. На рисунке 4.5 представлены фактические и расчетные значения средней урожайности сои за 2010–2019 гг. Также была проведена 10-кратная кросс-валидация модели. Средняя ошибка кросс-валидации составила 7,8 %.

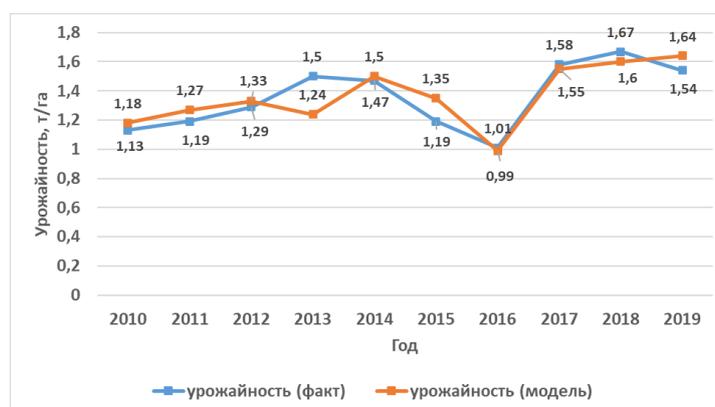


Рисунок 4.5 – Реальная и расчётная урожайность в Хабаровском районе

4.2 Раннее прогнозирование урожайности сои с использованием значений NDVI и количества дней вегетации

Решение практических сельскохозяйственных задач часто требует как можно более раннего прогнозирования урожайности сельскохозяйственных культур. При этом максимум NDVI для сои обычно достигается только во второй половине августа. Если учесть временные затраты на получение и обработку снимков, прогноз урожайности возможен только в конце августа.

4.2.1 Область исследования

Для оценки возможности, точности и сроков прогнозирования урожайности сои с использованием расчётного максимума NDVI были выбраны два соепроизводящих муниципальных образования Еврейской автономной области (ЕАО) – Ленинский и Октябрьский муниципальные районы (рисунок 4.6).

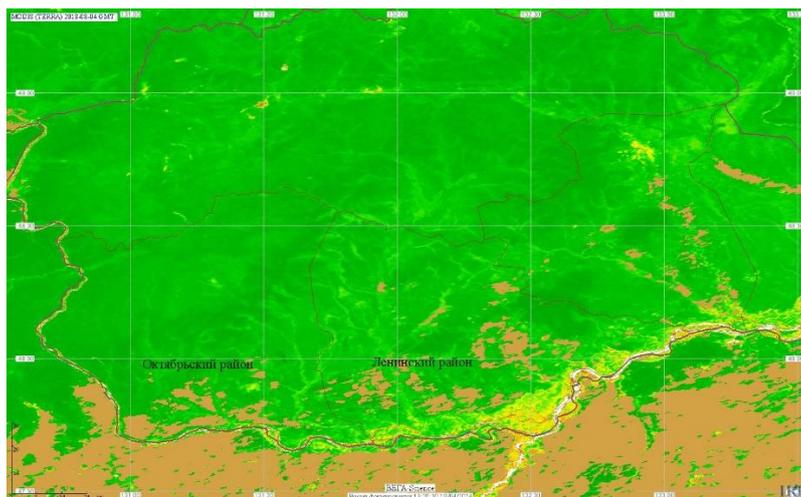


Рисунок 4.6 – Ленинский и Октябрьский районы ЕАО (композиционное изображение MODIS NDVI). Коричневым цветом показана маска пахотных земель

Ленинский район расположен на Среднеамурской низменности между $47^{\circ}40'$ – $48^{\circ}25'$ с.ш. и $131^{\circ}40'$ – $133^{\circ}00'$ в.д. Общая площадь пахотных земель в 2018 г. составила 80 982 га. Посевы сои занимают практически всю площадь пашни района (78 971 га, или 97,5 % от общей площади пашни). Октябрьский район расположен на юго-западе Еврейской автономной области (ЕАО) и граничит с Ленинским районом на востоке. Пахотные земли расположены на юге района между $47^{\circ}40'$ – $48^{\circ}05'$ с.ш. и $130^{\circ}50'$ – $131^{\circ}45'$ в.д. Общая площадь пахотных земель Октябрьского района в 2018 г. составила 48 892 га. Соя является практически монокультурой и в этом районе ЕАО (46 456 га, или 95 % от площади пашни).

Специализация сельского хозяйства обоих районов на выращивании сои позволяет использовать для прогнозирования её урожайности маску пахотных земель. Для создания временных рядов применялись композиты MODIS NDVI за период

с 15 по 42 календарную неделю с 2008 по 2017 г., для расчёта количества дней вегетации – данные реанализа о температуре воздуха (с 2013 по 2017 г.). В качестве маски использовался фрагмент маски пахотных земель, относящийся к данным муниципальным образованиям. Все входные данные моделей получены при помощи сервиса Vega-Science. Для обучения и оценки точности регрессионных моделей использовались сведения об урожайности сои в Ленинском и Октябрьском районе за 2013–2017 гг. (данные Росстата).

4.2.2 Принципы построения моделей для раннего прогнозирования урожайности

Предложенный в 4.1.1 метод аппроксимации сезонного хода NDVI позволяет рассчитать максимальное значение, используя доступные к дате прогнозирования значения временного ряда. Значение второго независимого параметра (x_3) для соответствующих календарных недель может быть получено путем прибавления к уже достигнутому количеству дней активной вегетации на момент прогнозирования всех оставшихся календарных дней до недели предполагаемого максимума. Это связано с тем, что в летние месяцы в южных сельскохозяйственных районах Дальнего Востока среднесуточная температура практически не опускается ниже 10 °С (так, в Хабаровском районе в период с 2010 по 2019 г. таких дней было всего три).

Для прогнозирования максимума NDVI использовались параметры функции Гаусса, рассчитанные для усредненного временного ряда за 5 лет, предшествующих году прогноза. Формула функции Гаусса (4.1) позволяет очевидным образом получить значение максимума $NDVI_{max}^{pred}$ на расчётной неделе i при подстановке параметров функции для усреднённого временного ряда за 5 лет, предшествующих прогнозу:

$$NDVI_{max}^{pred} = \frac{NDVI_i}{e^{-\frac{(i-b)^2}{2c^2}}}, \quad (4.6)$$

В качестве альтернативы функции Гаусса рассматривалась двойная логистическая функция (DL), ранее применявшаяся для аппроксимации временных рядов

вегетационных индексов [158]. Выбор именно этой функции обусловлен тем, что в отличие от полиномов и тригонометрических функций, DL так же, как и функция Гаусса, позволяет рассчитывать значение максимума вегетации до его достижения по средним многолетним параметрам. Формула расчета $NDVI_{max}^{pred}$ с использованием функции DL имеет следующий вид:

$$NDVI_{max}^{pred} = \frac{NDVI_i + NDVI_{min}(B-1)}{B}, \quad (4.7)$$

где $NDVI_{min}$ – минимальное значение NDVI за период с 15 по 42 календарную неделю года;

$$B = \left(\frac{1}{1 + \exp\left(\frac{a_1 - i}{a_2}\right)} - \frac{1}{1 + \exp\left(\frac{a_3 - i}{a_4}\right)} \right);$$

a_1, a_2, a_3, a_4 – параметры усреднённого временного ряда за 5 лет, предшествующих прогнозу;

i – неделя прогнозирования.

Для предварительной оценки максимума NDVI был выбран период с 25 недели (третья декада июня), когда резко начинает увеличиваться фотосинтетически активная биомасса, до 32 недели года (вторая декада августа), предшествующей достижению максимума NDVI сои в районах ЕАО. Для каждой недели указанного периода (2013–2017 гг.) рассчитывались значения относительной ошибки (APE) прогнозирования максимума NDVI и урожайности:

$$APE_{ij} = \frac{|y_{ij}^{pred} - y_j^{obs}|}{y_j^{obs}} \times 100, \quad (4.8)$$

где i – номер недели прогнозирования;

j – год прогнозирования.

Для оценки значимости различий точности прогнозирования с использованием функции Гаусса и функции DL, а также между Ленинским и Октябрьскими районами производился двухфакторный анализ (ANOVA) с использованием апостериорного критерия Тьюки.

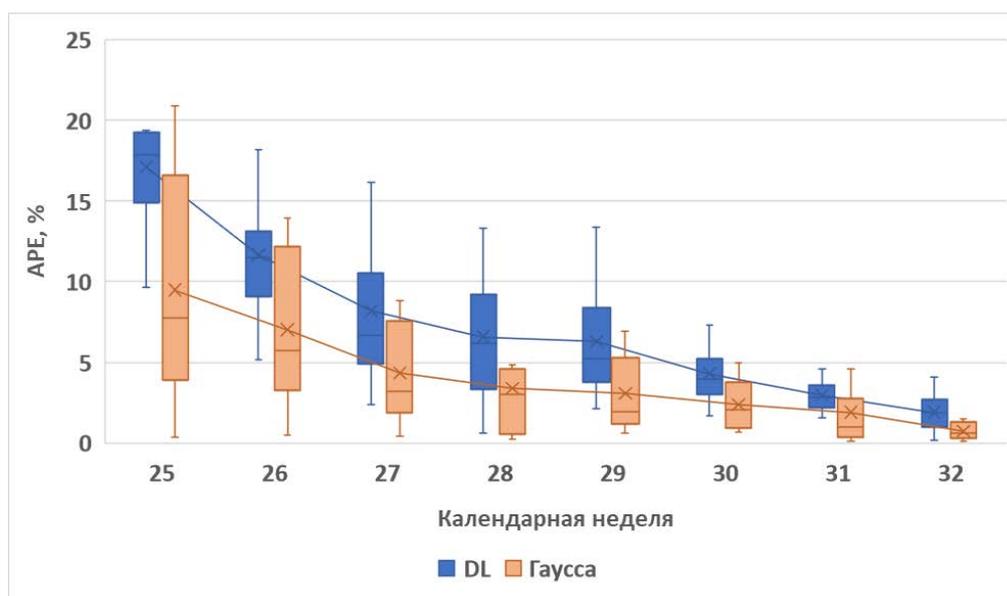


Рисунок 4.7 – Ошибка прогнозирования максимума NDVI с использованием функций Гаусса и DL в период с 25 по 32 календарную неделю (2013–2017 гг.)

4.2.4 Прогнозирование урожайности сои в районах ЕАО с использованием расчётных максимумов NDVI

Уравнения линейной регрессии, аналогичные уравнению (4.5), были построены для Ленинского и Октябрьского районов ЕАО. Для Октябрьского района уравнение для расчёта урожайности имеет следующий вид:

$$y = -2,43 + 2,83x_1 + 0,011x_3. \quad (4.9)$$

Для Ленинского района уравнение линейной регрессии следующее:

$$y = -0,79 + 1,45x_1 + 0,006x_3. \quad (4.10)$$

R^2 для модели (4.9) составил 0,59, MAPE – 6,8 %. R^2 для модели (4.10) составил 0,59, MAPE – 4,5 %. Для построения моделей использовались фактические данные о максимальных значениях NDVI за 2013–2017 гг. Прогнозирование урожайности осуществлялось на 33 календарной неделе, когда достигался максимум NDVI.

В таблице 4.6 представлены значения APE прогнозирования урожайности сои (2013–2017 гг.), рассчитанные по значениям NDVI в год по параметрам функций Гаусса и DL для усреднённого за предыдущие 5 лет временного ряда NDVI. В ходе двухфакторного анализа выявлено, что в течение большей части периода прогноза (с 25 по 30 неделю) ошибка прогнозирования по максимуму NDVI, рассчитанного с использованием функции Гаусса, значимо ниже ($p < 0,05$), чем при применении функции DL. В то же время значимых различий в точности прогнозирования между районами не выявлено ($p > 0,05$). Средняя ошибка прогнозирования урожайности в начале рассматриваемого периода с использованием функции DL на 25–26 неделе превышает 20 %, в то время как при использовании функции Гаусса она находится на уровне ниже 15 % на протяжении всего периода прогноза. Прогнозирование урожайности сои с точностью, превышающей 90 % с использованием расчёта максимума на основе функции Гаусса, возможно уже на 27 неделе, в то время как точность прогнозирования на основе функции DL превышает 90 % только начиная с 30 недели. На рисунке 4.8 представлена динамика ошибки прогнозирования урожайности сои для двух функций (2013–2017 г.). Таким образом, использование подхода на основе функции Гаусса позволяет осуществлять прогнозирование урожайности с приемлемой точностью уже за 6 недель до достижения максимума вегетации.

Модель раннего прогнозирования урожайности апробировалась для трех других соепроизводящих районах Дальнего Востока. В каждом регионе было выбрано по одному муниципальному образованию. В Амурской области раннее прогнозирование проводилось для Тамбовского района, в Хабаровском крае – для Вяземского района, а в Приморском крае – для Хорольского района. В качестве данных для регрессионных моделей применялись рассчитанные с использованием функции Гаусса (в период с 25 календарной недели до недели достижения максимума) максимальные значения NDVI и x_3 в период с 2013 по 2017 г. Значения R^2 для уравнения линейной регрессии составили 0,76 для Тамбовского района, 0,68 для Вяземского района, 0,83 для Хорольского района. В таблице 4.7 представлена динамика MAPE при приближении к максимуму NDVI.

Таблица 4.6 – Результаты двухфакторного дисперсионного анализа для прогнозирования урожайности сои в районах ЕАО

Фактор	Значение	APE, %							
		Неделя прогнозирования урожайности							
		25	26	27	28	29	30	31	32
Функция	Гаусса	14,9± 8,8	12,9± 6,7	9,3± 4,4	7,3± 2,6	6,2± 2,8	5,1± 2,4	5,0± 2,8	5,4± 4,2
	DL	32,8± 11,0	22,5± 7,2	16,3± 7,3	12,7± 6,8	11,7± 5,1	9,9± 4,2	7,7± 3,1	7,3± 3,9
P		p<0,0 5	p<0,05	p<0,05	p<0,05	p<0,05	p<0,05	p>0,05	p>0,0 5
Район	Ленинский	20,6± 8,2	14,1± 4,0	10,2± 3,5	7,8± 4,2	7,5± 4,0	7,2± 3,8	7,3± 3,9	7,0± 4,5
	Октябрьский	27,1± 13,8	21,3± 9,8	16,6± 8,8	12,5± 6,1	9,7± 3,9	7,3± 3,7	6,9± 3,1	6,5± 4,5
P		p>0,0 5	p>0,05	p>0,05	p>0,05	p>0,05	p>0,05	p>0,05	p>0,0 5

В Хорольском районе Приморского края максимум NDVI достигнут на 32 неделе, ошибка прогнозирования урожайности за 4 недели до достижения максимума (во второй декаде июля) составила около 10 %. При расчёте урожайности за 1–3 недели до достижения максимума MAPE опускалась ниже 5 %. В Тамбовском районе максимум по маске пахотных земель приходился на 31 календарную неделю. Прогнозирование с точностью свыше 90 % также возможно во второй декаде июля (за 3 недели до максимума), при приближении к максимуму ошибка прогнозирования урожайности увеличивается. В Вяземском районе максимум NDVI достигался уже на 30 неделе. При этом ошибка прогнозирования, начиная с первой декады июля (за 3 недели до достижения максимума), становилась меньше 9 %.

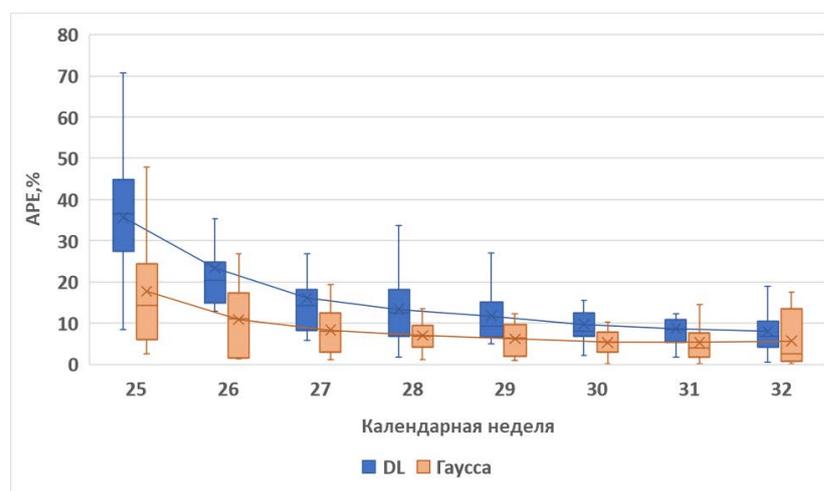


Рисунок 4.8 – Ошибка прогнозирования урожайности сои с использованием функций Гаусса и DL в период с 25 по 32 календарную неделю (2013–2017 гг.)

Таблица 4.7 – Оценка точности прогнозирования урожайности в разных муниципальных районах Дальнего Востока по мере приближения к максимуму NDVI (2013–2017 гг.)

Район	MAPE в неделю прогноза, %						
	25	26	27	28	29	30	31
Тамбовский	23,8	20,7	13,8	9,4	11,6	14,0	–*
Вяземский	12,2	10,9	8,8	8,1	7,8	–	–
Хорольский	18,5	17,5	14,3	10,4	4,9	1,7	4,1

* достижение максимума NDVI.

4.3 Выводы по четвертому разделу

Предложены принципы построения регрессионных моделей для предварительной оценки урожайности сельскохозяйственных культур на уровне муниципальных образований с использованием расчетного значения сезонного максимума вегетационного индекса NDVI и количества дней активной вегетации. Для построения средних временных рядов NDVI сельскохозяйственных культур на районном уровне могут использоваться данные MODIS и маски пахотных земель (в случае основной культуры района). Предложенный в работе метод аппроксимации сезонного хода позволяет получить прогнозируемое максимальное значе-

ние NDVI, используя параметры аппроксимирующих функций для усредненного за 5 предыдущих лет временного ряда и доступные к дате прогнозирования значения временного ряда прогнозного года. Проведено сравнение двух аппроксимирующих функций (функции Гаусса и функции DL). Применение двухфакторного анализа и апостериорного критерия Тьюки позволило выявить, что ошибка прогнозирования максимума NDVI при использовании функции Гаусса значимо ниже, чем для функции DL ($p < 0,05$).

Для оценки принципов построения моделей раннего прогнозирования были построены модели для пяти соепроизводящих районов Дальнего Востока. Для всех исследуемых районов использование данных ДЗЗ (значения NDVI) и климатических данных (количество дней вегетации) позволяет прогнозировать урожайность сои на 27–28 календарной неделях (первая половина июля) с ошибкой, не превышающей 10 %. Для некоторых исследуемых районов возможно использовать разработанные модели раннего прогнозирования уже во второй половине июня: ошибка прогнозирования урожайности при этом составляет менее 14 %.

ЗАКЛЮЧЕНИЕ

По результатам проведённого диссертационного исследования разработана методика мониторинга пахотных земель на основе дешифрирования данных ДЗЗ, позволяющая контролировать соблюдение севооборотов и восстанавливать сведения о сельскохозяйственных полях, а также прогнозировать урожайность сельскохозяйственных культур. При решении поставленных задач получены следующие результаты.

1. Выполнен анализ существующих методов сельскохозяйственного мониторинга с использованием данных ДЗЗ, доказана необходимость разработки методов распознавания культур и прогнозирования урожайности, учитывающих региональные особенности Дальнего Востока; выявлена проблема недостаточности и недостоверности данных о севообороте в регионах Дальнего Востока, показана необходимость восстановления сведений о землях сельскохозяйственного назначения; описаны методы распознавания посевов сельскохозяйственных культур с использованием данных ДЗЗ и машинного обучения.

2. Предложен способ построения непрерывных временных рядов композитов вегетационного индекса NDVI с использованием аппроксимации рядами Фурье; разработаны алгоритмы распознавания посевов основных сельскохозяйственных культур Дальнего Востока с использованием как данных оптических диапазонов (рядов индекса NDVI), так и данных радиолокации (рядов индекса DpRVI); ошибка классификации на основе NDVI не превышала 4 %, а на основе DpRVI – 18 %; предложенная методика распознавания сельскохозяйственных культур с использованием сезонных рядов NDVI применена для построения карт пахотных земель Хабаровского района в 2021–2023 гг.

3. Предложен алгоритм раннего распознавания посевов сельскохозяйственных культур с использованием временных рядов NDVI; точность классификации находилась в диапазоне от 88 до 92 %; проведены оценка площадей залежи и посевов сои, а также сравнение полученных результатов с данными официальной

статистики (в 2019–2020 гг. было выявлено превышение заявленной площади посевов сои до 30 %).

4. Предложены принципы построения моделей раннего прогнозирования урожайности сои, основанных на расчёте максимума вегетации с использованием параметров аппроксимации кривых NDVI за предыдущие 5 лет; установлена возможность прогнозирования с точностью свыше 90 % на 5–6 недель раньше регрессионных моделей на основе фактического максимума NDVI; произведена оценка точности моделей для муниципальных образований субъектов Дальнего Востока.

Результаты исследования могут быть рекомендованы к использованию органам исполнительной власти (региональным министерствам сельского хозяйства) для картографирования сельскохозяйственных угодий Дальнего Востока, восстановления сведений о севообороте, оценки объемов неиспользуемой пашни (для введения неиспользуемых земель в севооборот), прогнозирования урожайности сельскохозяйственных культур на районном уровне (в том числе, в оперативном режиме). Предложенные в работе методики могут применяться и в других сельскохозяйственных регионах (с поправкой на региональные особенности).

Перспективными направлениями дальнейших исследований является использование данных высокого пространственного разрешения для уточнения границ сельскохозяйственных полей и выявления неоднородностей вегетации в рамках одного сельскохозяйственного поля, прогнозирования урожайностей на уровне отдельных хозяйств и участков, а также оценки состояния мелиоративных систем.

СПИСОК ЛИТЕРАТУРЫ

1 Агрометеорологическая оценка состояния озимых зерновых культур в период прекращения вегетации с использованием наземных и спутниковых данных на примере Приволжского федерального округа / А. И. Страшная, С. А. Барталев, Т. А. Максименкова [и др.]. – Текст : непосредственный // Труды Гидрометцентра России. – 2014. – Вып. 351. – С. 85–105.

2 Анализ возможности использования данных различного пространственного разрешения при проведении мониторинга объектов / А. В. Кашницкий, Е. А. Лупян, Д. Е. Плотников, В. А. Толпин. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2023. – Т. 20. – № 2. – С. 60–74.

3 Аппроксимация временных рядов индексов вегетации (NDVI и EVI) для мониторинга сельхозкультур (посевов) Хабаровского края / А. С. Степанов, Е. А. Фомина, Л. В. Илларионова, К. Н. Дубровин, Д. В. Федосеев. – Текст: непосредственный // Информатика и автоматизация. – 2023. – Т. 22, № 6. – С. 1473–1498 (К1).

4 Асеева, Т. А. Приемы расширенного воспроизводства плодородия тяжелосуглинистых почв Приамурья / Т. А. Асеева. – Текст : непосредственный // Почвоведение и агрохимия. – 2015. – № 2. – С.107–116.

5 База данных показателей муниципальных образований [сайт]. – URL: <https://rosstat.gov.ru/dbscripts/munst> (дата обращения: 12.03.2021). – Текст : электронный.

6 Балдина, Е. А. Картографирование современного состояния и многолетних изменений в использовании сельскохозяйственных земель в дельте Волги / Е. А. Балдина, К. А. Трошко. – Текст : непосредственный // Геодезия и картография. – 2016. – № 11. – С. 39–46.

7 Беленко, В. В. Мониторинг объектов природно-экологического каркаса застраиваемых территорий по материалам космических съёмок / В. В. Беленко. –

Текст: непосредственный // Теоретическая и прикладная экология. – 2019. – № 3. – С. 21–27.

8 Беленко, В. В. Научно-методическое обеспечение градостроительного картографирования застраиваемых территорий по материалам космической съемки / В. В. Беленко. – Текст: непосредственный // Известия высших учебных заведений. Геодезия и аэрофотосъемка. – 2018. – Т. 62, № 3. – С. 346–356.

9 Береза, О. В. О возможности прогнозирования урожайности озимой пшеницы в Среднем Поволжье на основе комплексирования наземных и спутниковых данных / О. В. Береза, А. И. Страшная, Е. А. Лупян. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2015. – Т. 12, № 1. – С. 18–30.

10 Блок работы с данными дистанционного зондирования Земли Единой федеральной информационной системы о землях сельскохозяйственного назначения / К. А. Буланов, П. В. Денисов, Е. А. Лупян [и др.]. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2019. – Т. 16. – № 3. – С. 171–182.

11 Воронина, П. В. Классификация тематических задач мониторинга сельского хозяйства с использованием данных дистанционного зондирования MODIS / П. В. Воронина, Е. А. Мамаш. – Текст : непосредственный // ЖВТ. – 2014. – № 3. – С. 76–102.

12 Гайдученко, А. Н. Научно обоснованный севооборот и оптимизация технологических приемов возделывания – основа повышения продуктивности сои / А. Н. Гайдученко, С. Л. Оборский, Л. И. Топорова. – Текст : непосредственный // Дальневосточный аграрный вестник. – 2009. – № 2. – Т. 10. – С. 30–33.

13 Гордиенко, А. С. Разработка методики многоступенчатого дешифрирования космических снимков / А. С. Гордиенко, М. А. Алтынцев, А. С. Арбузов. – Текст : непосредственный // Известия высших учебных заведений. Геодезия и аэрофотосъемка. – 2011. – № 2. – С. 29–32.

14 Гук, А. П. Разработка методики определения изменений границы леса по разновременным разномасштабным аэрокосмическим снимкам / А. П. Гук,

Л. Г. Евстратова, М. А. Алтынцев // Геодезия и картография. – 2015. – № 12. – С. 32–39. – EDN VIBCTX.

15 Дворкин, Б. А. Европейская программа GMES и перспективная группировка спутников ДЗЗ Sentinel / Б. А. Дворкин. – Текст: непосредственный // Геомастика. – 2011. – № 3. – С. 14–26.

16 Дубровин, К. Н. Использование нейронных сетей для классификации пахотных земель южной части российского Дальнего Востока / К. Н. Дубровин, А. С. Степанов. – Текст : непосредственный // Агрофизический институт: 90 лет на службе земледелия и растениеводства: Материалы международной научной конференции, Санкт-Петербург, 14–15 апреля 2022 года. – Санкт-Петербург : Агрофизический научно-исследовательский институт, 2022. – С. 885–890.

17 Дубровин, К. Н. Классификация земель сельскохозяйственного назначения с использованием данных дистанционного зондирования Земли из космоса / К. Н. Дубровин, А. С. Степанов, А. Л. Верхотуров. – Текст : непосредственный // Региональные проблемы дистанционного зондирования Земли : материалы IX Международной научной конференции, Красноярск, 13–16 сентября 2022 года. – Красноярск: Сибирский федеральный университет, 2022. – С. 49–52.

18 Дубровин, К. Н. Решение задач идентификации сельскохозяйственных культур и актуализации границ сельскохозяйственных полей (на примере Хабаровского муниципального района) / К. Н. Дубровин, Л. В. Илларионова, А. С. Степанов. – Текст : непосредственный // Вестник СГУГиТ. – 2025. – Т. 30, № 1. – С. 48–58 (К1).

19 Единая федеральная информационная система о землях сельскохозяйственного назначения [сайт]. – URL: <https://efis.mcx.ru/landing> (дата обращения: 12.04.2024). – Текст : электронный.

20 Земельный кодекс Российской Федерации. № 136-ФЗ от 25 октября 2001 года : федеральный закон: [принят Государственной думой 28 сентября 2001 года] – Собрание законодательства Российской Федерации. – № 44. – Ст. 4147. – Текст: непосредственный.

21 Идентификация сельскохозяйственных культур с использованием радарных изображений / К. Н. Дубровин, А. С. Степанов, А. Л. Верхотуров, Т. А. Асеева. – Текст : непосредственный // Информатика и автоматизация. – 2022. – Т. 21, № 2. – С. 405–426.

22 Использование материалов дистанционного зондирования Земли в Единой федеральной информационной системе о землях сельскохозяйственного назначения (ЕФИС ЗСН) / И. С. Козубенко, Р. Р. Бегляров, Н. М. Вандышева [и др.]. – Текст : непосредственный // Материалы 2-й Всерос. научной конф. с международным участием «Применение средств дистанционного зондирования Земли в сельском хозяйстве», Санкт-Петербург, 26–28 сент. 2018. Санкт-Петербург : ФГБНУ АФИ, 2018. – С. 19–25.

23 Казяк, Е. В. Картографирование структуры посевных площадей с применением снимков Landsat-8 (на примере Минской области Республики Беларусь) / Е. В. Казяк, Э. А. Терехин. – Текст : непосредственный // Региональные геосистемы. – 2015. – № 21 (218). – С. 127–131.

24 Казяк, Е. В. Спектральные преобразования космических снимков Landsat 8 для картографирования растительности агроэкосистем/ Е. В. Казяк, А. В. Лещенко. – Текст : непосредственный // Интерэкспо ГЕО-Сибирь-2015. XI Междунар. науч. конгр. : Междунар. науч. конф. «Дистанционные методы зондирования Земли и фотограмметрия, мониторинг окружающей среды, геоэкология»: сб. материалов (Новосибирск, 13–25 апреля 2015 г.). – Новосибирск : СГУГиТ, 2015. – Т. 1. – С. 79–83.

25 Картографирование динамики растительного покрова территории национального парка «Куршская коса» по материалам космической съемки Alos и Sentinel-2/ А. Д. Никитина, С. В. Князева, Е. А. Гаврилюк [и др.]. – Текст : непосредственный // Вопросы лесной науки. – 2019. – № 3. – С. 4.

26 Катаев, М. Ю. Возможности космического мониторинга для целей сельского хозяйства Томской области / М. Ю. Катаев, А. А. Скугарев, И. Б. Сорокин. – Текст : непосредственный // Доклады ТУСУР. – 2017. – № 3. – С. 186–190.

27 Кононов, В. М. Алгоритм подготовки мультиспектральных спутниковых данных для задачи классификации сельскохозяйственных культур / В. М. Кононов, Р. Г. Асадуллаев, Н. И. Кузьменко. – Текст : непосредственный // Научный результат. Информационные технологии. – 2020. – № 2. – С. 18–24.

28 Космический комплекс «Канопус-В» – Текст : электронный // Госкорпорация «Роскосмос» [сайт]. – 2018. – URL: <https://www.roscosmos.ru/24985> (дата обращения: 16.12.2023).

29 Литвинчук, О. В. Гречиха – ценная крупяная культура для Томской области: наставления для сельхозпроизводителей / О. В. Литвинчук. – Томск : СибНИИСХиТ – филиал СФНЦА РАН, 2020. – 94 с. – Текст : непосредственный.

30 Лысенко, С. А. Прогнозирование урожайности сельскохозяйственных культур на основе спутникового мониторинга динамики углерода в наземных экосистемах / С. А. Лысенко. – Текст : непосредственный // Исследование Земли из космоса. – 2019. – № 4. – С. 48–59.

31 Миклашевич, Т. С. Интерполяционный алгоритм восстановления длинных временных рядов данных спутниковых наблюдений растительного покрова / Т. С. Миклашевич, С. А. Барталев, Д. Е. Плотников. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2019. – № 16(6). – С. 143–154.

32 Моделирование динамики вегетационного индекса NDVI озимой пшеницы в условиях ЦФО/ А. Г. Буховец, Е. А. Семин, Е. И. Костенко, С. И. Яблоновская. – Текст : непосредственный // Вестник Воронежского государственного аграрного университета. – 2018. – Т. 11. – № 2.– С. 186–199.

33 Нур, М. Разработка методики применения данных космических съемок для мониторинга лесов: специальность 25.00.34 «Аэрокосмические исследования Земли, фотограмметрия»: диссертация на соискание ученой степени кандидата технических наук / Нур Манзур; Государственный университет по землеустройству – Москва, 2021. – 150 с. – Текст : непосредственный.

34 Опыт использования данных прибора КМСС КА «Метеор-М» № 2 для задач мониторинга сельскохозяйственных угодий юга Хабаровского края /

Л. В. Илларионова, А. С. Степанов, К. Н. Дубровин, Е. А. Фомина, А. А. Сорокин, А. Л. Верхотуров, В. А. Елисеев. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2025. – Т. 22, № 1. – С. 81–92.

35 Опыт прогнозирования урожайности сельскохозяйственных культур с использованием имитационных моделей/ Е. В. Федотова, Ю. А. Маглинец, Р. В. Брежнев, А. И. Стародубцев. – Текст : непосредственный // Вестник КрасГАУ. – 2020. – № 8(161). – С. 43–48.

36 Особенности проведения классификации сельскохозяйственных земель Хабаровского края с использованием спутниковых данных / А. С. Степанов, К. Н. Дубровин, А. Л. Верхотуров, Т. А. Асеева. – Текст : непосредственный // Дальневосточный аграрный вестник. – 2022. – Т. 16, № 4. – С. 54–62.

37 Оценка точности выявления посевов озимых культур в весенне-летний период вегетации по данным прибора MODIS / Д. Е. Плотников, С. А. Барталев, Е. А. Лупян, В. А. Толпин. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2017. – Т. 14. – № 4. – С. 132–148.

38 Панеш, А. Х. Прогнозирование урожайности озимой пшеницы на основе сервисов геоинформационных систем/ А. Х. Панеш, Г. В. Цалов. – Текст : непосредственный // Вестник Адыгейского государственного университета. Серия 4: Естественно-математические и технические науки. – 2017. – № 4 (211). – С. 175–180.

39 Перспективы использования оптических и радарных изображений для контроля за соблюдением севооборотов в Хабаровском крае / А. С. Степанов, К. Н. Дубровин, А. Л. Верхотуров, Н. А. Селезнёва, А. А. Суняйкин. – Текст : непосредственный // Достижения науки и техники АПК. – 2021. – Т. 35, № 12. – С. 23–28.

40 Применение данных ДЗЗ в решении задач идентификации и прогнозирования урожайности сельскохозяйственных культур на Дальнем Востоке / А. С. Степанов, К. Н. Дубровин, Л. В. Илларионова, Е. А. Фомина. – Текст : непо-

средственный // Региональные проблемы дистанционного зондирования Земли: Материалы IX Международной научной конференции, Красноярск, 13–16 сентября 2022 года / Научный редактор Е. А. Ваганов, отв. редактор Г. М. Цибульский. – Красноярск : Сибирский федеральный университет, 2022. – С. 286–289.

41 Принципы агроландшафтного районирования пахотных земель Северного Казахстана по данным LANDSAT и MODIS/ А. Г. Терехов, И. С. Витковская, М. Ж. Батырбаева, Л. Ф. Спивак. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2010. – Т. 7, № 3. – С. 292–304.

42 Прогнозирование урожайности сельскохозяйственных культур на основе спутниковых данных: возможности и перспективы / И. Ю. Савин, С. А. Барталев, Е. А. Лупян [и пр.]. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2010. – Т. 7. – № 3. – С. 275–285.

43 Распознавание пахотных земель на основе многолетних спутниковых данных спектрорадиометра MODIS и локально-адаптивной классификации / С. А. Барталёв, В. А. Егоров, Е. А. Лупян [и др.]. – Текст : непосредственный // Компьютерная оптика. – 2011. – № 1. – С. 103–116.

44 Рухович, Д. Применение данных дистанционного зондирования Земли для организации ретроспективного мониторинга земельного покрова / Д. Рухович. – Текст : непосредственный // Земля из космоса. – 2016. – № 5 (21). – С. 41–49.

45 Савин, И. Ю. Причины многолетней динамичности индекса NDVI (MODIS), осредненного для пахотных земель на уровне муниципалитетов Белгородской области / И. Ю. Савин, Ю. Г. Чендев. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2018. – Т. 15. – № 2. – С. 137–143.

46 Савицкая, О. В. Методы спутникового мониторинга оценки состояния и продуктивности посевов зерновых культур: специальность 25.00.30 «Метеорология, климатология, агрометеорология»: диссертация на соискание ученой степени кандидата географических наук / Ольга Владимировна Савицкая; Всерос-

сийский научно-исследовательский институт сельскохозяйственной метеорологии. – Обнинск, 2016. – 184 с. – Текст : непосредственный.

47 Свидетельство о государственной регистрации № 2020612600 программы для ЭВМ Российская Федерация. Программный комплекс для прогнозирования урожайности сельскохозяйственных культур : № 2019667148 : дата поступления 24.12.2019 : дата регистрации 27.02.2020 / К. Н. Дубровин, А. С. Степанов ; правообладатель Федеральное государственное бюджетное учреждение науки «Хабаровский Федеральный исследовательский центр Дальневосточного отделения Российской академии наук» (RU). – Текст : непосредственный.

48 Свидетельство о государственной регистрации № 2022680556 программы для ЭВМ Российская Федерация. Программный комплекс для моделирования временных рядов вегетационных индексов с использованием аппроксимирующих функций: № 2022669010 : дата поступления 14.10.2022 : дата регистрации 02.11.2022 / К. Н. Дубровин, Е. А. Фомина, А. С. Степанов, Л. В. Илларионова ; правообладатель Федеральное государственное бюджетное учреждение науки «Хабаровский Федеральный исследовательский центр Дальневосточного отделения Российской академии наук» (RU). – Текст : непосредственный.

49 Свидетельство о государственной регистрации № 2024684901 программы для ЭВМ Российская Федерация. Программный комплекс автоматизированной обработки композитных изображений спутника Метеор для получения сезонных временных рядов NDVI для сельхозугодий Хабаровского края: № 2024683116 : дата поступления 08.10.2024 : дата регистрации 22.10.2024 / Л. В. Илларионова , А. С. Степанов, Е. А. Фомина , К. Н. Дубровин, А. С. Бордаков ; правообладатель Федеральное государственное бюджетное учреждение науки «Хабаровский Федеральный исследовательский центр Дальневосточного отделения Российской академии наук» (RU). – Текст : непосредственный.

50 Свидетельство о государственной регистрации базы данных № 2024620115 Российская Федерация. Результаты мониторинга сельскохозяйственных угодий юга Дальнего Востока: № 2023624666: дата поступления 11.12.2023 : дата регистрации 11.01.2024 / Д. В. Федосеев, К. Н. Дубровин,

А. С. Степанов, Л. В. Илларионова, А. Л. Верхотуров, И. О. Прохорец ; правообладатель Федеральное государственное бюджетное учреждение науки «Хабаровский федеральный исследовательский центр Дальневосточного отделения Российской академии наук» (RU). – Текст : непосредственный.

51 Своеволина, А. В. Возможности методов активного дистанционного зондирования земли для мониторинга сельскохозяйственных угодий / А. В. Своеволина, А. Ю. Чермошенцев. – Текст : непосредственный // Интерэкспо Гео-Сибирь. – 2021. – № 5. – С. 262–267.

52 Система «Вега-Science»: особенности построения, основные возможности и опыт использования/ Е. А. Лупян, А. А. Прошин, М. А. Бурцев [и др.]. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2021. – Т. 18. – № 6. – С. 9–31.

53 Спивак, Л. Ф. Анализ результатов прогнозирования урожайности яровой пшеницы на основе временных рядов статистических данных и интегральных индексов вегетации / Л. Ф. Спивак, И. С. Витковская, М. Ж. Батырбаева. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2015. – Т. 12. – № 2. – С. 173–182.

54 Степанов, А. С. Влияние климатических характеристик и значений вегетационного индекса NDVI на урожайность сои (на примере районов Приморского края) / А. С. Степанов, Т. А. Асеева, К. Н. Дубровин. – Текст : непосредственный // Аграрный вестник Урала. – 2020. – № 1(192). – С. 10–19.

55 Степанов, А. С. Моделирование вегетационных циклов сои в южной части Дальнего Востока на основе оптических и радарных спутниковых изображений / А. С. Степанов, К. Н. Дубровин. – Текст : непосредственный // Достижения науки и техники АПК. – 2023. – Т. 37, № 6. – С. 80–85.

56 Степанов, А. С. Моделирование сезонной динамики NDVI и LAI сельскохозяйственных культур юга Дальнего Востока (на примере сои) / А. С. Степанов, К. Н. Дубровин. – Текст : непосредственный // Применение средств дистанционного зондирования Земли в сельском хозяйстве: Материалы III Всероссийской научной конференции с международным участием, Санкт-Петербург, 16–17 сен-

тября 2021 года. – Санкт-Петербург: Агрофизический научно-исследовательский институт РАСХН, 2021. – С. 80–83.

57 Степанов, А. С. Построение и оценка точности регрессионных моделей для определения урожайности зерновых и зернобобовых культур на основе данных дистанционного зондирования Земли и климатических характеристик / А. С. Степанов, Т. А. Асеева, К. Н. Дубровин. – Текст : непосредственный // ИнтерКарто. ИнтерГИС. – 2020. – Т. 26, № 3. – С. 159–169.

58 Степанов, А. С. Прогнозирование урожайности сельскохозяйственных культур на основе данных дистанционного зондирования Земли (на примере сои) / А. С. Степанов. – Текст : непосредственный // Вычислительные технологии. – 2019. – Т. 24. – № 6. – С. 125–133.

59 Табунщик, В. А. Применение спутниковых снимков Sentinel-2 для анализа земель, используемых в сельском хозяйстве (на примере Раздольненского района Республики Крым) / В. А. Табунщик, Е. А. Петлюкова, М. О. Хитрин. – Текст : непосредственный // Труды Карадагской научной станции им. Т. И. Вяземского – Природного заповедника РАН. – 2018. – № 1(5). – С. 43–57.

60 Терехин, Э. А. Анализ спектрально-отражательных свойств залежных земель Среднерусской лесостепи по данным Sentinel-2 / Э. А. Терехин. – Текст : непосредственный // Компьютерная оптика. – 2023. – Т. 47, № 2. – С. 306–313.

61 Трошко, К. А. Интерферометрическая когерентность по данным Sentinel-1 для мониторинга сельскохозяйственных работ (на примере Амурской области) / К. А. Трошко, П. В. Денисов. – Текст : непосредственный // Материалы 18-й Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса». – Москва : ИКИ РАН, 2020. – С. 372.

62 Федеральная служба государственной статистики [сайт]. – URL: <https://rosstat.gov.ru> (дата обращения: 14.07.2023). – Текст : электронный.

63 Федеральный фонд данных ДЗЗ из космоса. Особенности предоставления данных ДЗЗ физическим и юридическим лицам / А. В. Павлов, И. А. Никитин, А. В. Гронь, Т. Ю. Головина. – Текст : непосредственный // Региональные проблемы дистанционного зондирования Земли : материалы IX Международной

научной конференции, Красноярск, 13–16 сентября 2022 года / Научный редактор Е. А. Ваганов, отв. редактор Г. М. Цибульский. – Красноярск : Сибирский федеральный университет, 2022. – С. 65–67.

64 Шатрова, К. В. Модель представления информации о состоянии и динамике земель сельскохозяйственного назначения / К. В. Шатрова, Ю. А. Маглинец, Г. М. Цибульский. – Текст : непосредственный // Журнал СФУ. Техника и технологии. – 2014. – Т. 7. – № 8. – С. 984–989.

65 Шукилович, А. Ю. Применение сенсора MODIS для оперативного мониторинга земель сельскохозяйственного назначения / А. Ю. Шукилович, Е. В. Федотова, Ю. А. Маглинец. – Текст : непосредственный // Журнал СФУ. Техника и технологии. 2016. – № 7. – С. 1035–1044.

66 Якушев, В. П. Опыт применения и перспективы развития технологий дистанционного зондирования Земли для сельского хозяйства / В. П. Якушев, Н. Н. Дубенок, Е. А. Лупян. – Текст : непосредственный // Современные проблемы дистанционного зондирования Земли из космоса. – 2019. – Т. 16, № 3. – С. 11–23.

67 10 m crop type mapping using Sentinel-2 reflectance and 30 m cropland data layer product/ К. Н. Tran, Н. К. Zhang, J. T. McMaine [и др.]. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2022. – Vol. 107. – P. 102692.

68 A curve fitting procedure to derive inter-annual phenologies from time series of noisy satellite NDVI data / В. А. Bradley, R. W. Jacob, J. F. Hermance, J. F. Mustard. – Текст : непосредственный // Remote Sensing of Environment. – 2007. – Vol. 106 (2). – P. 137–145.

69 A deep learning framework for crop mapping with reconstructed Sentinel-2 time series images/ F. Feng, M. Gao, R. Liu [и др.]. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2023. – Vol. 213. – P. 108227.

70 A new locally-adaptive classification method LAGMA for large-scale land cover mapping using remote-sensing data / S. A. Bartalev, V. A. Egorov, E. A. Loupian,

S. A. Khvostikov. – Текст : непосредственный // Remote Sensing Letters. – 2014. – Vol. 5(1). – P. 55–64.

71 A Phenology-Based Classification of Time-Series MODIS Data for Rice Crop Monitoring in Mekong Delta, Vietnam / N. T. Son, C. F. Chen, C. R. Chen [и др.]. – Текст : непосредственный // Remote Sensing. – 2014. – Vol. 6. – P. 135–156.

72 Alaska Satellite Facility Distributed Active Archive Center [сайт]. – URL: <https://search.asf.alaska.edu/#> (дата обращения: 29.11.2021). – Текст : электронный.

73 An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping / X.-P. Song, W. Huang, M.C. Hansen, P. Potapov. – Текст : непосредственный // Science of Remote Sensing. – 2021. – Vol. 3. – P. 100018.

74 An Interannual Transfer Learning Approach for Crop Classification in the Hetao Irrigation District, China/ Y. Hu, H. Zeng, F. Tian [и др.]. – Текст : непосредственный // Remote Sensing. – 2022. – Vol. 14. – P. 1208.

75 Arias, M. Crop Classification Based on Temporal Signatures of Sentinel-1 Observations over Navarre Province, Spain/ M. Arias, M.Á. Campo-Bescós, J. Álvarez-Mozos. – Текст : непосредственный // Remote Sensing. – 2020. – Vol. 12. – P. 278.

76 Asgarian, A. Crop type mapping in a highly fragmented and heterogeneous agricultural landscape: A case of central Iran using multi-temporal Landsat 8 imagery / A. Asgarian, A. Soffianian, S. Pourmanafi. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2016. – Vol. 127. – P. 531–540.

77 Balaghi, R. Empirical regression models using NDVI, rainfall and temperature data for the early prediction of wheat grain yields in Morocco/ R. Balaghi, B. Tychon, H. Eerens. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2008. – Vol. 10. – P. 438–452.

78 Bolton, D. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics/ D. Bolton, M. Friedl. – Текст : непосредственный // Agricultural and Forest Meteorology. – 2013. – Vol. 173. – P. 74–84.

79 Boosting methods for multi-class imbalanced data classification: an experimental review / J. Tanha, Y. Abdi, N. Samadi [и др.]. – Текст: непосредственный // Journal of Big Data. – 2020. – Vol. 7–70.

80 Breiman, L. Random forests / L. Breiman. – Текст : непосредственный // Machine Learning. – 2001. – Vol. 45. – P. 5–32.

81 Characterizing and mapping cropping patterns in a complex agro-ecosystem: An iterative participatory mapping procedure using machine learning algorithms and MODIS vegetation indices/ G. L. Feyisa, L. K. Palao, A. Nelson [и др.]. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2020. – Vol. 17. – P. 105595.

82 Chen, T. XGBoost: A Scalable Tree Boosting System/ T. Chen, C. Guestrin. – Текст : непосредственный // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16), San Francisco, USA. August 13-17, 2016. – P. 785–794.

83 Chen, Y. A practical approach to reconstruct high-quality Landsat NDVI time-series data by gap filling and the Savitzky–Golay filter / Y. Chen, R. Cao, J. Chen. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2021. – Vol. 180. – P. 174–190.

84 Copernicus programme [сайт]. – URL: <https://www.copernicus.eu/en> (дата обращения: 16.06.2023). – Текст : электронный.

85 Crop type mapping from pansharpened Landsat 8 NDVI data: A case of a highly fragmented and intensive agricultural system / J.-E. Ouzemou, A. El Harti, R. Lhissou [и др.]. – Текст : непосредственный // Remote Sensing Applications: Society and Environment. – 2018. – Vol. 11. – P. 94–103.

86 Crop type mapping in the central part of the North China Plain using Sentinel-2 time series and machine learning/ K. Luo, L. Lu, Y. Xie [и др.]. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2023. – Vol. 205. – P. 107577.

87 de la Casaa, A. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot/ A. de la Casaa, G.

Ovandoa, L. Bressanini. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2018. – Vol. 146. – P. 531–547.

88 Deep learning-based crop mapping in the cloudy season using one-shot hyperspectral satellite imagery/ S. Meng, X. Wang, X. Hu [и др.]. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2021. – Vol. 186. – P. 106188.

89 Dual polarimetric radar vegetation index for crop growth monitoring using Sentinel-1 SAR data/ D. Mandal, V. Kumar, D. Ratha [и др.]. – Текст : непосредственный // Remote Sensing of Environment. – 2020. – Vol. 247. – P. 111954.

90 Dubrovin, K. Cropland mapping using Sentinel-1 data in the southern part of the Russian Far East / K. Dubrovin, A. Stepanov, A. Verkhoturov. – Текст : электронный // Sensors. – 2023. – Vol. 23, No. 18. – P. 7902.

91 Dubrovin, K. N. Application of LAI and NDVI to model soybean yield in the regions of the Russian Far East / K. N. Dubrovin, A. S. Stepanov, T. A. Aseeva. – Текст : электронный // IOP Conference Series: Earth and Environmental Science, Yekaterinburg, 15–16 октября 2021 года. – Yekaterinburg, 2022. – 012030.

92 Early-season crop type mapping using 30-m reference time series / P. Hao, H. Tang, Z. Chen [и др.]. – Текст : непосредственный // Journal of Integrative Agriculture. – 2020. – Vol. 19 (7). – P. 1897–1911.

93 Enhancement of Comparative Assessment Approaches for Synthetic Aperture Radar (SAR) Vegetation Indices for Crop Monitoring and Identification – Khabarovsk Territory (Russia) Case Study / A. Sorokin, A. Stepanov, K. Dubrovin, A. Verkhoturov. – Текст : электронный // Remote Sensing. – 2024. – Vol. 16. – 2532.

94 Erdanaev, E. Irrigated Crop Types Mapping in Tashkent Province of Uzbekistan with Remote Sensing-Based Classification Methods/ E. Erdanaev, M. Kappas, D. Wyss. – Текст : непосредственный // Sensors. – 2022. – Vol.22. – 5683.

95 ESA Sentinel Application Platform (SNAP) v.8.0 / разработчик: European Space Agency. – 2020. – Электронная программа: электронная.

96 ESA Sentinel-2 [сайт].
URL:<https://sentinel.esa.int/web/sentinel/missions/sentinel-2> (дата обращения: 12.05.2023). – Текст : электронный.

97 ESA WorldCover 10 m 2021 v200 / Zanaga D., Van De Kerchove R., Daems D. [и др.]. – Текст : непосредственный. – 2022.

98 Ferreira, A. J. Boosting algorithms: a review of methods, theory, and applications/ A. J. Ferreira, M. A. Figueiredo. – Текст : непосредственный // In: Ensemble machine learning. – Boston: Springer, 2012. – P. 35–85.

99 From cropland to cropped field: A robust algorithm for national-scale mapping by fusing time series of Sentinel-1 and Sentinel-2 / B. Qiu, D. Lin, C. Chen [и др.]. – Текст : непосредственный // International Journal of Applied Earth Observations and Geoinformation. – 2022. – Vol. 113. – P. 103006.

100 Gaso, D. Predicting wheat grain yield and spatial variability at field scale using a simple regression or a crop model in conjunction with Landsat images / D. Gaso, A. Berger, V. Ciganda. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2019. – Vol. 159. – P. 75–83.

101 Gavin, H. P. The Levenberg–Marquardt Method for Nonlinear Least Squares Curve-Fitting Problems / H. P. Gavin. – Текст : электронный. – URL: <http://people.duke.edu/~hpgavin/ce281/lm.pdf> (время обращения: 17.08.2023).

102 Gella, G. W. Mapping crop types in complex farming areas using SAR imagery with dynamic time warping/ G. W. Gella, W. Bijker, M. Belgiu. – Текст: непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2021. – Vol. 175. – P. 171–183.

103 Gómez, C. Optical remotely sensed time series data for land cover classification: A review/ C., J. C. White, M. A. Wulder. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2016. – Vol. 1162016. – P. 55–72.

104 Griffiths, P. Intra-annual reflectance composites from Sentinel-2 and Landsat for national-scale crop and land cover mapping / P. Griffiths, C. Nendel, P. Hostert. – Текст : непосредственный // Remote Sensing of Environment. – 2019. – Vol. 220. – P. 135–151.

105 High resolution crop intensity mapping using harmonized Landsat-8 and Sentinel-2 data/ P. Hao, H. Tang, Z. Chen [и др.]. – Текст : непосредственный // Journal of Integrative Agriculture. – 2019. – Vol. 18(12). – P. 2883–2897.

106 High-resolution mapping of regional VOCs using the enhanced space-time extreme gradient boosting machine (XGBoost) in Shanghai/ B. Lu, X. Meng, S. Dong [и др.] – Текст : непосредственный // Science of The Total Environment. – 2023. – Vol. 905. – P. 167054.

107 Huete, A. R. Soil-Adjusted Vegetation Index (SAVI) / A. R. Huete. – Текст : непосредственный // Remote Sensing of Environment. – 1988. – Vol. 25, № 3. – P. 295–309.

108 Identifying the contributions of multi-source data for winter wheat yield prediction in China / J. Cao, Z. Zhang, F. Tao [и др.]. – Текст : непосредственный // Remote Sensing. – 2020. – Vol.12. – P. 750.

109 Improved Early Crop Type Identification by Joint Use of High Temporal Resolution SAR And Optical Image Time Series / J. Inglada, A. Vincent, M. Arias, C. Marais-Sicre. – Текст: непосредственный // Remote Sensing. – 2016. – Vol. 8. – P. 362.

110 Improved regional-scale Brazilian cropping systems' mapping based on a semi-automatic object-based clustering approach / B. Bellón, A. Bégué, D. Lo Seen [и др.]. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2018. – Vol. 68. – P.127–138.

111 Improving the consistency of multi-temporal land cover mapping of Laguna Lake watershed using light gradient boosting machine (LightGBM) approach, change detection analysis, and Markov chain / C. Candido, A. C. Blanco, J. Medina [и др.]. – Текст : непосредственный // Remote Sensing Applications: Society and Environment. – 2021. – Vol. 23. – 100565.

112 Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories/ H. McNairn, C. Champagne, J. Shang, D. Holmstrom, G. Reichert. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2009. – Vol. 64 (5). – P. 434–449.

113 Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology/ P. M. Atkinson, C. Jeganathan, J. Dash, C. Atzberger. – Текст : непосредственный // Remote Sensing of Environment. – 2012. – Vol. 123. – P. 400–417.

114 Johnson, D. M. A comprehensive assessment of the correlations between field crop yields and commonly used MODIS products / D. M. Johnson. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2016. – Vol. 52. – P. 65–81.

115 Jonsson, P. Seasonality extraction by function fitting to time-series of satellite sensor data / P. Jonsson, L. Eklundh. – Текст : непосредственный // IEEE Transactions on Geoscience and Remote Sensing. – 2002. – Vol. 40 (8). – P. 1824–1832.

116 Julien, Y. Optimizing and comparing gap-filling techniques using simulated NDVI time series from remotely sensed global data/ Y. Julien, J. A. Sobrino. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2019. – Vol. 76. – P. 93–111.

117 Kim, Y. A Time-Series Approach to Estimate Soil Moisture Using Polarimetric Radar Data/ Y. Kim, J.J. van Zyl. – Текст : непосредственный // IEEE Transactions on Geoscience and Remote Sensing. – 2009. – Vol. 47 (8). – P. 2519–2527.

118 Kocur-Bera, K. Understanding information about agricultural land. An evaluation of the extent of data modification in the Land Parcel Identification System for the needs of area-based payments – a case study/ K. Kocur-Bera. – Текст : непосредственный // Land Use Policy. – 2020. – Vol. 94. – P. 104527.

119 Kowalik, W. Yield estimation using SPOT-VEGETATION products: A case study of wheat in European countries/ W. Kowalik, K. Dabrowska-Zielinska, M. Meroni. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2014. – Vol. 32. – P. 228–239.

120 Land Resources Monitoring, Modeling, and Mapping with Remote Sensing. Remote Sensing Handbook: Volume II / P. Teluguntla, P. Thenkabail, J. Xiong [и др.]. – Текст : непосредственный. – London : CRC Press, 2015. – 849 p.

121 LMFIT: Non-Linear Least-Squares Minimization and Curve-Fitting for Python / разработчик: LMFit Development Team. – 2021. – Электронная программа : электронная.

122 Mapping crop rotation by satellite-based data fusion in Southern Brazil / L. P. Pott, T. J. C. Amado, R. A. Schwalbert [и др.]. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2023. – Vol. 211. – P. 107958.

123 Mapping croplands, cropping patterns, and crop types using MODIS time-series data [Text] / Y. Chen, D. Lu, E. Moran [и др.]. – Текст : непосредственный // International Journal of Applied Earth, Observation and Geoinformation. – 2018. – Vol. 69.– P. 133–147.

124 Mapping crops within the growing season across the United States / V. S. Konduri, J. Kumar, W. W. Hargrove [и др.]. – Текст : непосредственный // Remote Sensing of Environment. – 2020. – Vol. 251. – P. 112048.

125 Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany/ L. Blickensdorfer, M. Schwider, D. Pflugmacher [и др.]. – Текст : непосредственный // Remote Sensing of Environment. – 2022. – Vol. 269. – 112831.

126 Matplotlib: Visualization with Python / разработчик: The Matplotlib development team. – 2012. – Электронная программа : электронная.

127 Michishita, R. Empirical comparison of noise reduction techniques for NDVI time-series based on a new measure/ R. Michishita, J. Chen, B. Xu. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2014. – Vol. 91. – P. 17–28.

128 Monitoring US Agriculture: the US Department of Agriculture, National Agricultural Statistics Service, Cropland Data Layer Program/ C. Boryan, Z. Yang, R. Mueller, M. Craig. – Текст : непосредственный // GeoCarto International. – 2011. – Vol. 26 (5). – P. 341–358.

129 Monitoring Vegetation Systems in the Great Plains with ERTS / J. W. Rouse, R. H. Haas, J. A. Scheel, D. W. Deering. – Текст : непосредственный // Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium. – 1974. – Vol. 1. – P. 48–62.

130 Multi-Year Cropland Mapping Based on Remote Sensing Data: A Case Study for the Khabarovsk Territory, Russia / K. Dubrovin, A. Verkhoturov, A. Stepanov, T. Aseeva. – Текст : электронный // Remote Sensing. – 2024. – Vol. 16(9). – P. 1633.

131 NASA. MODIS. Moderate Resolution Imaging Spectroradiometer [сайт]. – URL: <https://modis.gsfc.nasa.gov> (дата обращения: 5.05.2023). – Текст : электронный.

132 NASA's Earth Observing System [сайт]. – URL: <http://eosps.nasa.gov> (дата обращения: 28.05.2023). – Текст : электронный.

133 Onojeghuo, A. Applications of satellite 'hyper-sensing' in Chinese agriculture: Challenges and opportunities / A. Onojeghuo, G. Blackburn, J. Huang. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2018. – Vol. 64. – P. 62–86.

134 Overview of the radiometric and biophysical performance of the MODIS vegetation indices / A. Huete, K. Didan, T. Miura [и др.]– Текст : непосредственный // Remote Sensing of Environment. – 2002. – Vol. 83. – P. 195–213.

135 Pandas: Python Data Analysis Library / разработчик: AQR Capital Management. – 2012. – Электронная программа : электронная.

136 Prabhakara, K. Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States / K. Prabhakara, W. D. Hively, G. W. McCarty. – Текст : непосредственный // International Journal of Applied Earth Observation and Geoinformation. – 2015. – Vol. 39. – P. 88–102.

137 Predicting soybean yield at the regional scale using remote sensing and climatic data / A. Stepanov, T. Aseeva, K. Dubrovin, A. Sorokin. – Текст : непосредственный // Remote Sensing. – 2020. – Vol. 12, No. 12. – P. 1936.

138 Predicting soybean yield at the regional scale using remote sensing and climatic data / A. Stepanov, T. Aseeva, K. Dubrovin, A. Sorokin. – Текст : электронный // Remote Sensing. – 2020. – Vol. 12, No. 12. – P. 1936.

139 Predicting the Normalized Difference Vegetation Index (NDVI) by training a crop growth model with historical data/ A. Berger, G. Ettlin, C. Quincke, P. Rodríguez-Vosca. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2019. – Vol. 161. – P. 305–311.

140 Rasterio: access to geospatial raster data / разработчик: Mapbox. – 2018. – Электронная программа : электронная.

141 Sakamoto, T. Incorporating environmental variables into a MODIS-based crop yield estimation method for United States corn and soybeans through the use of a random forest regression algorithm / T. Sakamoto. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2020. – Vol.160. – P. 208–228.

142 Scikit-learn 1.4.2: machine learning in Python /разработчик: Scikit-learn developers. – 2023. – Электронная программа : электронная.

143 Shammi, S. A. Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling/ S. A. Shammi, Q. Meng. – Текст : непосредственный // Ecological Indicators. – 2021. –Vol. 121. – P. 107124.

144 Shao, Y. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS-NDVI multi-temporal data / Y. Shao, R.S. Lunetta, B. Wheeler. – Текст : непосредственный // Remote Sensing of Environment. – 2016. – Vol. 174. – P. 258–265.

145 Şimşek, F. Land cover classification using Land Parcel Identification System (LPIS) data and open source Eo-Learn library/ F. F. Şimşek, S. S. Durduran. – Текст : непосредственный //Geocarto International. – Vol. 38(1). – P. 1–18.

146 STATISTICA 12 / разработчик: Statsoft. – 2013. – Электронная программа : электронная.

147 Stepanov, A. Forecasting Soybean Yield in Agricultural Regions of the Russian Far East Using Remote Sensing Data / A. Stepanov, T. Aseeva, K. Dubrovin. –

Текст: непосредственный // Smart Innovation, Systems and Technologies. – 2022. – Vol. 245. – P. 349–358.

148 Stepanov, A. Function fitting for modeling seasonal normalized difference vegetation index time series and early forecasting of soybean yield / A. Stepanov, K. Dubrovin, A. Sorokin. – Текст : непосредственный // The Crop Journal. – 2022. – Vol. 10, No. 5. – P. 1452–1459.

149 Stepanov, A. S. Modelling soybean yield for the early prediction in the Russian Far East using remote sensing data / A. S. Stepanov, K. N. Dubrovin. – Текст : электронный // IOP Conference Series: Earth Environment and Science. – 2020. – Vol. 547. – 012039.

150 SURE-based optimum-length S-G filter to reconstruct NDVI time series iteratively with outliers' removal / L. Tang, Z. Zhao, P. Tang, H. Yang. – Текст : непосредственный // International Journal of Wavelets, Multiresolution and Information Processing. – 2020. – Vol. 18 (2). – P. 2050001.

151 Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium/ K. Van Tricht, A. Gobin, S. Gilliams, I. Piccard. – Текст : непосредственный // Remote Sensing. – 2018. – Vol. 10. – 1642.

152 The Fiona / разработчик: Sean Gillies. – 2011. – Электронная программа : электронная.

153 The Land Parcel Identification System – A useful tool to determine the eligibility of agricultural land – but its management could be further improved. Special report. – Текст : непосредственный // European Court of Auditors. – Publications Office, 2016. – № 252016.

154 Toshichika, I. Global crop yield forecasting using seasonal climate information from a multi-model ensemble/ I. Toshichika, Y. Shin, W. Kim. – Текст : непосредственный // Climate Services. – 2018. – Vol. 11. – P. 13–23.

155 USGS. Landsat Missions [сайт]. – URL: <https://landsat.usgs.gov> (дата обращения: 5.06.2023). – Текст : электронный.

156 Using NDVI Time Series for Interannual Cropland Classification in the Khabarovsk District / L. Illarionova, K. Dubrovin, A. Stepanov, T. Aseeva. – Текст:

непосредственный // Agriculture Digitalization and Organic Production: Proceedings of the Third International Conference on Agriculture Digitalization and Organic Production (ADOP 2023), St. Petersburg, 05–07 июня 2023 года. – St. Petersburg : Springer Nature Singapore, 2023. – P. 327–338.

157 Vermote, E. Atmospheric correction algorithm: Spectral reflectances (MOD09) / E. Vermote, A. Vermeulen. – Текст : непосредственный // 1999. – V. 4. – 107 p.

158 Vorobiova, N. Curve fitting of MODIS NDVI time series in the task of early crops identification by satellite images / N. Vorobiova, A. Chernov. – Текст : непосредственный // Procedia Engineering. – 2017. – Vol. 201. – P. 184–195.

159 WorldCover 2020: Product Validation Report / Tsendbazar N., Linlin L., Koopman M. [и др.]. – Текст : непосредственный. – 2021.

160 Yan, Y. Exploring Google Street View with deep learning for crop type mapping / Y. Yan, Y. Ryu. – Текст : непосредственный // ISPRS Journal of Photogrammetry and Remote Sensing. – 2021. – Vol. 171. – P. 278–296.

161 Yang, Y. P. Weighted double-logistic function fitting method for reconstructing the high-quality Sentinel-2 NDVI time series data set / Y. P. Yang, J. C. Luo, Q. T. Huang. – Текст : непосредственный // Remote Sensing. – 2019. – Vol. 11. – P. 18.

162 Yaramasu, R. Pre-season crop type mapping using deep neural networks / R. Yaramasu, V. Bandaru, K. Pnvr. – Текст : непосредственный // Computers and Electronics in Agriculture. – 2020. – Vol. 176. – P. 105664.

163 Zhou, J. Reconstruction of global MODIS NDVI time series: Performance of Harmonic ANalysis of Time Series (HANTS) / J. Zhou, L. Jia, M. Menenti. – Текст : непосредственный // Remote Sensing of Environment. – 2015. – Vol. 163. – P. 217–228.

ПРИЛОЖЕНИЕ А
(ОБЯЗАТЕЛЬНОЕ)

АКТ ВНЕДРЕНИЯ РЕЗУЛЬТАТОВ В РАМКАХ
НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЫ ПО ГОСУДАРСТВЕННОМУ
КОНТРАКТУ



МИНИСТЕРСТВО
СЕЛЬСКОГО ХОЗЯЙСТВА
И ПРОДОВОЛЬСТВИЯ
ХАБАРОВСКОГО КРАЯ

Муравьева-Амурского ул., д. 19, г. Хабаровск,
Хабаровский край, Российская Федерация, 680000
Тел. (4212) 32-77-64. Факс (4212) 30-51-50
E-mail: apk@khv.gov.ru; https://minsh.khabkrai.ru

25.02.2025 № 07.1-11-1009

На № _____ от _____

Об акте внедрения

Директору
ФГБУН ХФИЦ ДВО РАН
обособленное подразделение
ДВ НИИСХ

Асеевой Т.А.

Уважаемая Татьяна Александровна!

Министерство сельского хозяйства и продовольствия Хабаровского края направляет акт внедрения результатов в рамках выполнения научно-исследовательской работы по государственному контракту № 04 от 29 июля 2024 года по теме "Разработка методов раннего прогнозирования урожайности сельскохозяйственных культур Хабаровского края с использованием данных ДЗЗ (дистанционное зондирование Земли)", прилагается.
Приложение: на 1 л. в 1 экз.

Первый заместитель министра

А.В. Зейда

АКТ ВНЕДРЕНИЯ

Настоящий акт составлен о том, что результаты диссертационной работы на соискание ученой степени кандидата технических наук Дубровина Константина Николаевича на тему "Разработка методики мониторинга пахотных земель Дальнего Востока на основе данных дистанционного зондирования Земли и машинного обучения" использованы в рамках работы по государственному контракту № 04 от 29 июля 2024 года по теме "Разработка методов раннего прогнозирования урожайности сельскохозяйственных культур Хабаровского края с использованием данных ДЗЗ (дистанционное зондирование Земли)" для прогнозирования урожайности сельскохозяйственных культур (сои и овса) в муниципальных образованиях Хабаровского края (район имени Лазо и Хабаровский район) в 2024 году. Средняя ошибка модели прогнозирования урожайности сои составила 10,1 %, для овса – 14,3 %.

Начальник отдела
растениеводства управления
по развитию агропромышленного
комплекса и племенной работы
министерства сельского хозяйства
и продовольствия Хабаровского края

25.02.2025



О.В. Терехова

ПРИЛОЖЕНИЕ Б
(ОБЯЗАТЕЛЬНОЕ)

АКТ О ВНЕДРЕНИИ НАУЧНЫХ РАЗРАБОТОК
В ДЕЯТЕЛЬНОСТЬ

Федеральное государственное бюджетное учреждение науки
Хабаровский Федеральный исследовательский центр
Дальневосточного отделения Российской академии наук
обособленное подразделение

**Дальневосточный
научно-исследовательский
институт сельского
хозяйства
(ДВ НИИСХ)**

**Far Eastern Agricultural
Research Institute
(FEARI)**

13, Klubnaya str., Vostochnoe, kr.
Khabarovskiy, 680521, Russian Federation,
Tel: 8(4212)49-75-46,
E-mail: dvniish_delo@mail.ru

Место нахождения обособленного подразделения: Хабаровский край, Хабаровский р-он, с. Восточное
Почтовый адрес: 680521, Хабаровский край, Хабаровский район, с. Восточное, ул. Клубная, 13
тел. (4212) 49-75-46, факс (4212) 49-71-66, e-mail: dvniish_delo@mail.ru

АКТ

о внедрении научных разработок
Дубровина Константина Николаевича в деятельность
ДВ НИИСХ

Предложенные в диссертационной работе Дубровина Константина Николаевича «Разработка методики мониторинга пахотных земель Дальнего Востока на основе данных дистанционного зондирования Земли и машинного обучения» методы распознавания посевов сельскохозяйственных культур по данным дистанционного зондирования Земли из космоса используются при проведении мониторинга сельскохозяйственных земель Дальневосточного научно-исследовательского института сельского хозяйства (картографирования пахотных земель, уточнения границ полей, оценки состояния посевов).

Директор ДВ НИИСХ,
чл.-корр. РАН



16.12.2024

Т.А. Ацева