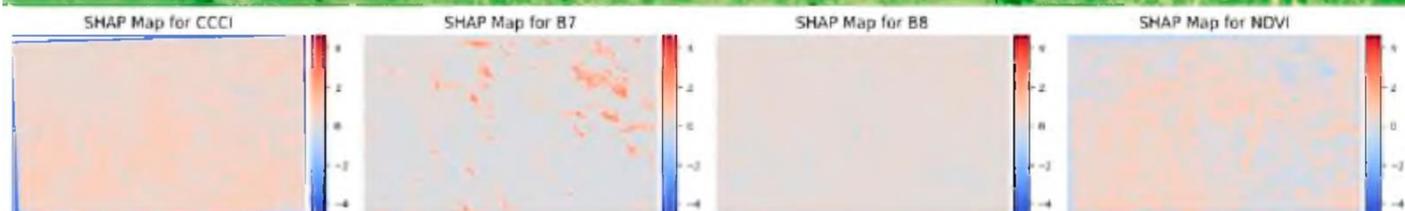
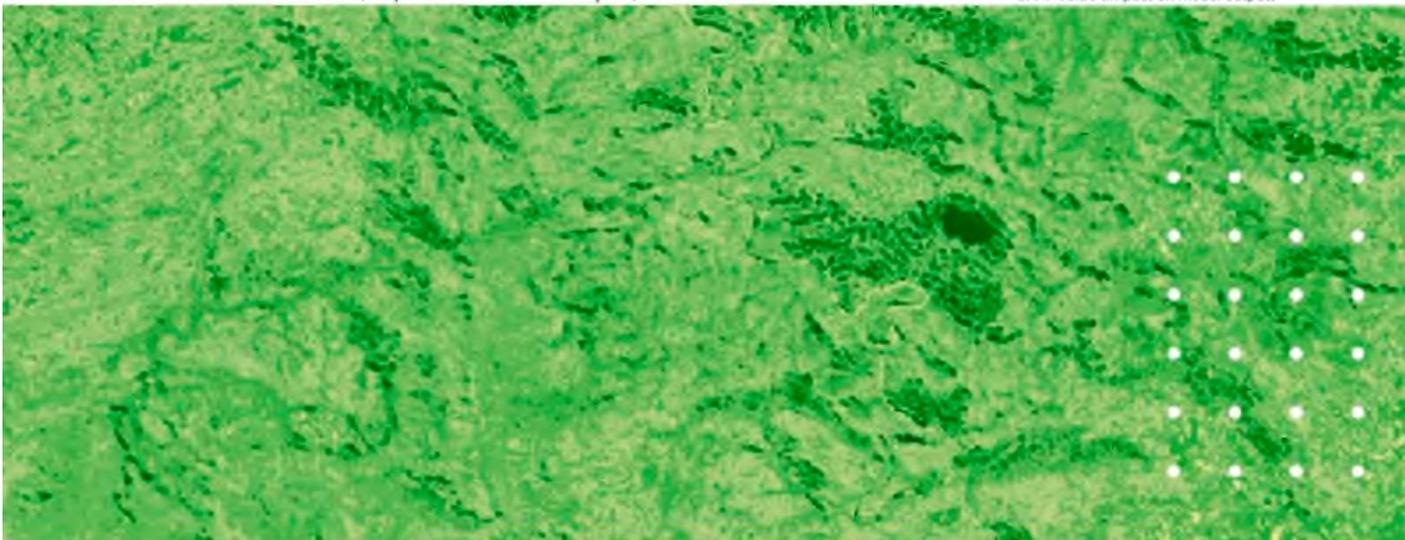
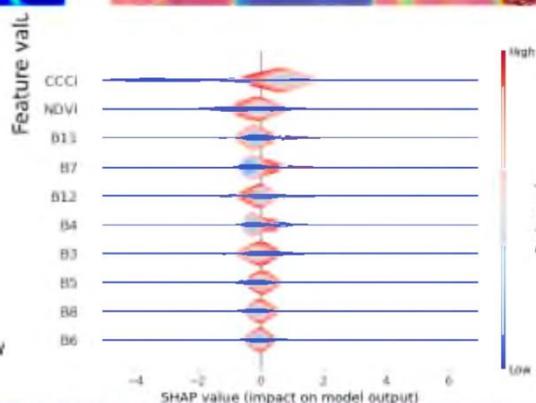
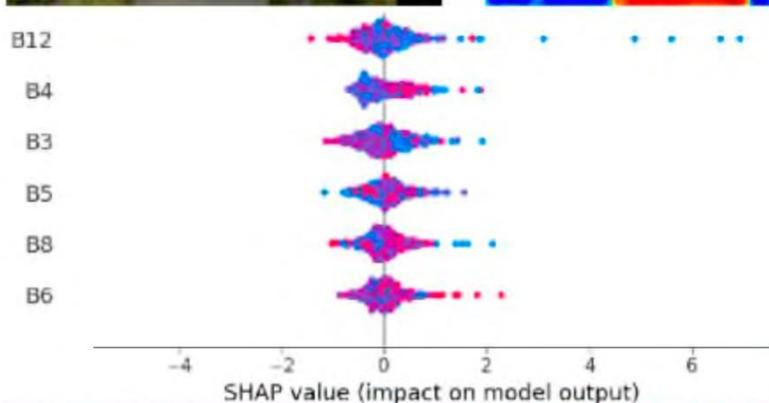
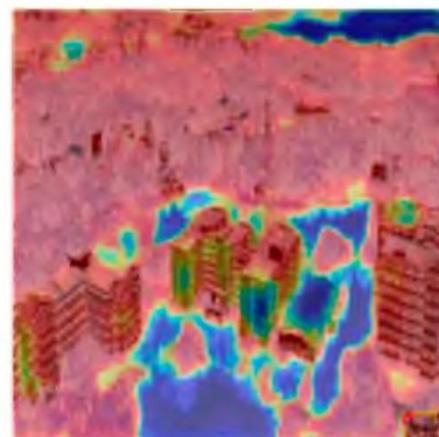
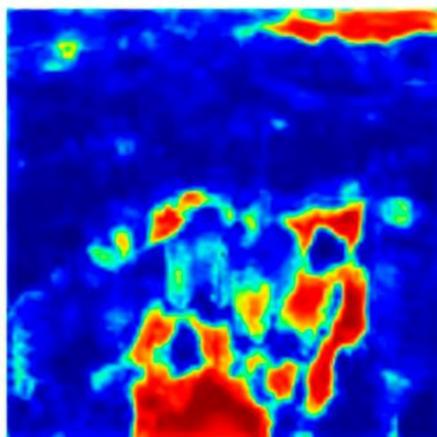


Представление ГеоИИ Тематические исследования в области объяснимого ГеоИИ для моделирования окружающей среды

Каридж Камюсоко



Российское общество геодезии, картографии и землеустройства

Каридж Камюсоко

**Представление ГеоИИ
Тематические исследования
в области объяснимого ГеоИИ
для моделирования окружающей среды**

Москва, 2025

УДК 004.89:528.854.46 528.88

ББК 32.813:26.12

© Каридж Камюсоко, 2024 г.

Рецензенты издания на русском языке:

Яблонский Л. И. – доктор технических наук, старший научный сотрудник, главный научный сотрудник Геоинформационного центра Российской академии наук;

Чечин А. В. – кандидат технических наук, доцент, заведующий кафедрой геоинформатики, геодезии и кадастра Нижегородского государственного архитектурно-строительного университета.

Камюсоко Каридж

Представление ГеоИИ. Тематические исследования в области объяснимого ГеоИИ для моделирования окружающей среды / Каридж Камюсоко ; пер. с англ. Г. Г. Побединского. - Москва: Российское общество геодезии, картографии и землеустройства, 2025. – 47 с. : ил. – Текст : электронный.

ISBN 978-5-9901203-2-7

В книге рассмотрено применение объяснимого искусственного интеллекта и геопространственного искусственного интеллекта в моделировании окружающей среды, начиная со структуры лесов и заканчивая картографированием последствий наводнений. Каждое тематическое исследование демонстрирует ценность методов искусственного интеллекта, таких как аддитивные объяснения Шепли и градиентно-взвешенное отображение активации классов.

Книга предназначена не только для исследователей геопространственных данных или ученых в области окружающей среды, но и для всех заинтересованных сторон, участвующих во внедрении геопространственного искусственного интеллекта в области охраны окружающей среды.

УДК 004.89:528.854.46 528.88

ББК 32.813:26.12

ISBN 978-5-9901203-2-7

© Каридж Камюсоко, 2024

© Г. Г. Побединский, перевод, 2025

© Издание и оформление на русском языке Российское общество геодезии, картографии и землеустройства, 2025

Оглавление

Предисловие к переводу	4
Предисловие	5
Глава 1. Введение в объяснимый ГеоИИ	8
1.1. Рост ГеоИИ	8
1.2. Почему в ГеоИИ важна объяснимость	10
1.3. Методы объяснимого ИИ (XAI)	10
1.3.1. Обзор методов машинного и глубокого обучения	10
1.3.2. Обзор методов объяснимого ИИ (XAI)	11
1.3.3. Методы объяснимого ИИ (XAI) для моделей ГеоИИ	13
1.4. Применение объяснимого ГеоИИ для моделирования окружающей среды	14
1.5. Краткие итоги	15
Глава 2. Практический пример 1: Объяснимое машинное обучение для моделирования структуры леса	15
2.1. Введение	15
2.2. Предварительный анализ данных	17
2.2.1. Данные о высоте леса GEDI	17
2.2.2. Анализ спектральной отражательной способности с использованием прямоугольных диаграмм	18
2.2.3. Анализ спектральной отражательной способности с использованием графиков плотности	19
2.3. Оценка эффективности модели	20
2.4. Интерпретация значений SHAP	22
2.4.1. Интерпретация глобальных значений SHAP	22
2.4.2. Интерпретация локальных значений SHAP	27
2.5. Пространственный анализ вклада предикторов с использованием SHAP	29
2.6. Краткие итоги	31
Глава 3. Практический пример 2: Объяснимое глубокое обучение для составления карт последствий наводнений	32
3.1. Введение	32
3.2. Модель U-Net	34
3.3. Карты паводковых зон	35
3.4. Интерпретация Grad-CAM	36
3.5. Краткие итоги	37
Глава 4. Преимущества объяснимого ИИ: почему будущее за геопространственным моделированием	38
4.1. Введение	38
4.2. Преимущества и ограничения объяснимого ГеоИИ для моделирования высоты полога леса	39
4.3. Преимущества и ограничения объяснимого ГеоИИ для картографирования последствий наводнений	40
4.4. Будущая работа	40
4.5. Следующие шаги: Как раскрыть весь потенциал объяснимого ГеоИИ	41
Литература	42
Приложение	44

Предисловие к переводу

В России, как и во всем мире, в последние годы повышенный интерес вызывает возможность применения искусственного интеллекта в геопространственной деятельности. В апреле 2024 года на II Всероссийской научно-практической конференции с международным участием «ГЕОФОРУМ. НИЖНИЙ НОВГОРОД 2024» представлен доклад «Геоинформационные системы и искусственный интеллект» <https://rosgeokart.ru/news/iivserossiyskaya-nauchno-prakticheskaya-konferenciya-s-mezhdunarodnym-uchastiem-geoforum-0>, вопросы применения искусственного интеллекта в геоинформатике рассматривались в мае 2024 года на научной конференции МИИГАиК «Пространственные данные: наука и технологии 2024» <https://scidata.miigaik.ru/?ysclid=m5jm0aa21c998560822>, тема «Искусственный интеллект и человек – какой будет новая реальность» и Олимпиада «Применение систем искусственного интеллекта в исследовании геосистем» рассматривались на XX Международной выставке и научном конгрессе «Интерэкспо ГЕО-Сибирь 2024» <https://geosib.sgugit.ru/>. В сентябре 2024 года на 4-й Международной научно-технической конференции «ЦИФРОВАЯ РЕАЛЬНОСТЬ: космические и пространственные данные, технологии обработки» проведено отдельное заседание «Искусственный интеллект в геоинформатике» <https://conf.racurs.ru/conf2024/>.

Одним из приоритетных направлений развития искусственного интеллекта является необходимость и способность объяснять решения, принимаемые на основе искусственного интеллекта. Тем самым преобразовать модели «черного ящика» в более прозрачные модели «стеклянного ящика». Рассмотрению этого направления посвящена работа Кариджа Камюсоко (Courage Kamusoko) – известного японского ученого в сфере анализа данных дистанционного зондирования Земли, моделировании растительного покрова и чрезвычайных ситуаций – «Представление ГеоИИ, Тематические исследования в области объяснимого геопространственного искусственного интеллекта (ГеоИИ) для моделирования окружающей среды» (GeoAI Unveiled: Case Studies in Explainable GeoAI for Environmental Modeling).

Несмотря на краткость и обзорный характер, эта работа достаточно полно раскрывает понятие геопространственного искусственного интеллекта, формулирует проблемы и решения его использования.

Предисловие

Геопространственный искусственный интеллект (ГеоИИ) быстро меняет то, как мы взаимодействуем с окружающей средой, открывая новые возможности для понимания ресурсов Земли и управления ими. В этом новом ландшафте, где искусственный интеллект (ИИ) и геопространственные технологии объединяются, способность объяснять решения, принимаемые на основе ИИ, и доверять им, становится приоритетом. Работа «Представление ГеоИИ. Тематические исследования в области объяснимого ГеоИИ для моделирования окружающей среды» устраняют критический разрыв между передовыми моделями ГеоИИ и прозрачностью, необходимой для их ответственного применения в контексте охраны окружающей среды.

За последнее десятилетие такие методы искусственного интеллекта, как машинное обучение (machine learning – ML) и глубокое обучение (deep learning – DL), привели к значительному прогрессу в геопространственных приложениях. В настоящее время эти технологии находятся на переднем крае решения некоторых наиболее острых экологических проблем в мире – вырубки лесов, изменения климата, урбанизации и стихийных бедствий. Однако, хотя ИИ обладает беспрецедентными возможностями прогнозирования, он также создает сложности. Зачастую непрозрачный характер моделей искусственного интеллекта, обычно называемых «черными ящиками», создает барьеры для доверия, особенно в таких важных ситуациях, как сохранение лесов, борьба с наводнениями, городское развитие и мониторинг климата.

Объяснимый ИИ (Explainable AI – XAI) предлагает решение, преобразующее сложные системы искусственного интеллекта в более прозрачные и понятные модели. Объяснимый ИИ также позволяет пользователям видеть, что предсказывает модель и почему она делает эти прогнозы. Эта возможность особенно важна в геопространственных контекстах, где результаты полученные с помощью искусственного интеллекта должны служить основой для принятия решений по охране окружающей среды, обеспечению общественной безопасности и управлению ресурсами.

В этой вводной книге исследуется мощное пересечение объяснимого ИИ (XAI) и ГеоИИ на примере конкретных примеров из реальной жизни. Глава за главой в ней рассматриваются важнейшие области применения объяснимого ГеоИИ в моделировании окружающей среды, начиная со структуры лесов и заканчивая картографированием последствий наводнений. Каждое тематическое исследование демонстрирует ценность методов искусственного интеллекта, таких как аддитивные объяснения Шепли (SHapley Additive explanations – SHAP) и градиентно-взвешенное отображение активации классов (Gradient-weighted Class Activation Mapping – Grad-CAM).

Представленный ГеоИИ предназначен не только для исследователей геопространственных данных или ученых в области окружающей среды, но и для всех заинтересованных сторон, участвующих во внедрении ГеоИИ для решений в области охраны окружающей среды. Независимо от того являетесь ли вы аспирантом, исследователем, государственным служащим, градостроителем или специалистом по ликвидации чрезвычайных ситуаций, эта книга поможет вам в полной мере использовать потенциал ГеоИИ. Она также гарантирует, что модели ГеоИИ остаются прозрачными, объяснимыми и подотчетными. Книга снабдит вас знаниями и инструментами, позволяющими уверенно ориентироваться в сложном ландшафте ГеоИИ в области мониторинга и управления окружающей средой.

На следующих страницах вы узнаете, как объяснимый ГеоИИ может помочь преодолеть проблемы доверия и прозрачности, которые долгое время ограничивали использование

искусственного интеллекта в моделировании окружающей среды. Предлагаемая книга – не просто техническое руководство, она предлагает перспективное видение того, как ответственный объяснимый ИИ может изменить нашу способность решать сложные проблемы окружающей среды. Это вносит ощутимый вклад в управление природными ресурсами Земли и их защиту.

Поскольку мы отправляемся в это путешествие по ГеоИИ, я приглашаю вас выйти за рамки «черного ящика» и принять обещание объяснимого будущего. Это путешествие, в котором объяснимый ГеоИИ служит мощным инструментом и надежным партнером в решении проблем окружающей среды нашего времени.

Как устроена эта книга?

Структура книги «Представление ГеоИИ. Тематические исследования в области объяснимого ГеоИИ для моделирования окружающей среды» позволяет читателям ознакомиться с основными концепциями, методами и областями применения объяснимого ИИ (ХАИ) в ГеоИИ. Книга состоит из четырех ключевых глав. Цель состоит в том, чтобы дать всестороннее представление о том, как ГеоИИ может быть применен для решения проблем окружающей среды, обеспечивая при этом прозрачность и объяснимость моделей искусственного интеллекта. Книга организована следующим образом.

Глава 1. Введение в объяснимый ГеоИИ

Глава закладывает основу книги, знакомя с концепцией ГеоИИ и ее растущей актуальностью в геопространственных технологиях. В ней рассматривается быстрый рост геопространственных приложений, управляемых искусственным интеллектом, и подчеркивается важность объяснимости этих моделей. В этой главе представлены основные принципы, лежащие в основе объяснимого ИИ (ХАИ), а также такие методы, как аддитивные объяснения Шепли (SHapley Additive explanations – SHAP), не зависящие от модели локальные интерпретируемые объяснения (Local Interpretable Model-Agnostic Explanations – LIME) и градиентно-взвешенное отображение активации классов (Gradient-weighted Class Activation Mapping – Grad-CAM). Читатели получают четкое представление о том, почему объяснимость имеет решающее значение, особенно при моделировании окружающей среды.

Глава 2. Практический пример 1: Объяснимое машинное обучение для моделирования структуры леса

В тематическом исследовании показано, как применять регрессионный метод случайного леса (Random Forest Regression) для прогнозирования высоты лесного покрова с использованием данных наблюдений Земли, таких как данные о высоте лесного покрова GEDI и снимки Sentinel-2. Подробное объяснение важности прогнозирующих факторов (предикторов) приводится с использованием значений SHAP. Читатели узнают, как различные предикторы, такие как полосы частот Sentinel-2 и спектральные индексы, влияют на выходные данные модели. В этом тематическом исследовании подчеркивается важность объяснимого машинного обучения (ML) для оценки структуры лесов.

Примечание переводчика. Sentinel-2 - спутники дистанционного зондирования Земли (ДЗЗ) Европейского космического агентства, созданные в рамках проекта глобального мониторинга окружающей среды и безопасности «Коперник» (Copernicus). Спутники предназначены для мониторинга использования земель, растительности, лесных и водных ресурсов, могут применяться при ликвидации последствий стихийных бедствий. Первый спутник Sentinel-2А запущен 23 июня 2015 г. Характеристики каналов Sentinel-2: В1 60 м, 433-453 нм, В2 10 м, 458-522 нм, В3 10 м, 543-577 нм, В4 10 м, 650-680 нм, В5 20 м, 698-712 нм, В6 20 м, 733-747 нм, В7 20 м, 773-793 нм, В8 10 м, 784-899 нм, В8А 20 м, 855-875 нм, В9 60 м, 935-955 нм, В10 60 м, 1360-1390 нм, В11 20 м, 1565-1655 нм, В12 20 м, 2100-2280 нм.

Примечание переводчика. Global Ecosystem Dynamics Investigation (GEDI) - проект НАСА по измерению того, как вырубка лесов повлияла на концентрацию CO₂ в атмосфере. Система LIDAR GEDI предоставляет точные данные о высоте с привязкой к местности, которые значительно улучшают глобальные цифровые модели рельефа (ЦМР).

Глава 3. Практический пример 2: Объяснимое глубокое обучение для составления карт последствий наводнений

Во втором практическом примере методы глубокого обучения (Deep Learning – DL) применяются для составления карт наводнений с использованием изображений высокого разрешения. В главе представлена модель U-Net и показано, как ее можно использовать для определения затопленных районов. Градиентно-взвешенное отображение активации классов (Grad-CAM) используется для визуализации того, какие части спутниковых изображений повлияли на прогнозы модели.

Глава 4. Преимущества объяснимого ИИ: почему будущее за геопространственным моделированием

В заключительной главе приводится краткое изложение книги и рассматриваются сильные и слабые стороны современных методов объяснимого ГеоИИ. В ней подчеркивается необходимость обеспечения прозрачности при принятии решений, основанных на ГеоИИ. В ней также рассматриваются новые направления исследований и важность разработки поддающихся интерпретации моделей, которые решают технические и этические проблемы. Центральной темой этой главы является роль объяснимого ГеоИИ в обеспечении ответственного и справедливого использования ИИ.

Приложение

В книгу также включено приложение, в котором содержится дополнительная литература, для тех, кто заинтересован в применении обсуждаемых методов. Эти ресурсы предназначены для того, чтобы помочь читателям углубить понимание объяснимого ГеоИИ и использовать его в своих проектах.

Глава 1. Введение в объяснимый ГеоИИ

1.1. Рост ГеоИИ

Несомненно, геопространственные технологии стали неотъемлемой частью нашей повседневной жизни. В большинстве стран мира геопространственные данные и технологии вносят свой вклад в нашу жизнь. Мы постоянно взаимодействуем с информационными системами – от Google Maps, с помощью которых мы ездим на работу, – до отслеживания доставки пиццы или просто прогнозирования погоды на наших мобильных телефонах. Однако несколько десятилетий назад обработка наборов геопространственных данных была серьезной проблемой из-за ограниченного объема устройств хранения данных и вычислительной мощности. Только эксперты имели возможность работать с большими наборами геопространственных данных на национальном, региональном или глобальном уровнях. Теперь, благодаря достижениям в облачных вычислениях и свободному доступу к геопространственным данным, стало возможным создавать даже карты растительного покрова по всей стране, обработка геопространственных данных стала намного более выполнимой и эффективной. Опираясь на эти достижения, геопространственные технологии вступают в новую эру, основанную на искусственном интеллекте (ИИ).

Новый рубеж в области геопространственных данных и технологий – геопространственный искусственный интеллект (ГеоИИ), который преобразует возможности геопространственных приложений. ГеоИИ интегрирует искусственный интеллект с геопространственными данными, наукой и технологиями для решения сложных геопространственных задач и улучшения понимания [VoPham et al., 2018; Li et al., 2024]. Используя методы искусственного интеллекта, ГеоИИ генерирует ценную геопространственную информацию на основе геопространственных данных [Pierdicca & Paolanti, 2022]. Недавние достижения в области искусственного интеллекта, в частности машинного обучения (ML) и глубокого обучения (DL), в сочетании с увеличением вычислительной мощности продвинули ГеоИИ вперед. Эти разработки позволили использовать их в различных областях применения, таких как картографирование растительного покрова, мониторинг лесов, городское планирование и моделирование климата [Liu & Biljecki, 2022].

Рост ГеоИИ также обусловлен обилием геопространственных данных и быстрым прогрессом в технологиях обработки и хранения данных. Огромные объемы геопространственных данных – от спутниковых снимков высокого разрешения до сенсорных наблюдений в режиме реального времени – требуют надежных, масштабируемых и эффективных возможностей хранения и анализа. Эти возможности имеют решающее значение для сбора жизненно важных наборов данных об окружающей среде и деятельности человека, помогая нам лучше понимать динамические экологические и социальные системы [Gao et al., 2023]. Одновременно достижения в области технологий искусственного интеллекта и движение за открытую науку способствуют разработке новых стратегий обучения.

Включение пространственных характеристик в модели искусственного интеллекта является ключевым аспектом ГеоИИ [Goodchild, 2004]. Геопространственные данные и процессы обладают уникальными свойствами, такими как пространственная автокорреляция и пространственная неоднородность. Пространственная автокорреляция, описываемая первым законом географии Тоблера, гласит, что объекты, расположенные в непосредственной близости, более похожи, чем удаленные объекты. То есть пространственная автокорреляция измеряет сходство значений для данной переменной на основе географической близости. Этот принцип лежит в основе разработки пространственных алгоритмов, таких как пространственная кластеризация и интерполяция. Пространственная неоднородность, часто называемая пространственной нестационарностью, описывает различия в отношениях, процессах или характеристиках в разных географических точках [Anselin, 1989]. Это означает, что экологические, социально-экономические или экологические феномены не остаются постоянными в пространстве. Вместо этого, такие явления демонстрируют различия, которые

варьируются от местоположения к местоположению из-за влияния различных местных факторов. Новые модели ГеоИИ все чаще включают это свойство для решения проблемы пространственной неоднородности [Georganos et al., 2021; Xie et al., 2021]. Например, [Xie et al., 2021] разработана система глубокого обучения с учетом пространственной неоднородности, которая использует многомерную статистику сканирования для выявления пространственной неоднородности во входных данных. Этот подход обеспечивает иерархическое пространственное разделение исследуемой области [Xie et al., 2021] по нескольким моделям глубокого обучения, что приводит к более надежным прогнозам, по сравнению с другими моделями искусственного интеллекта.

Недавней разработкой в ГеоИИ является Prithvi, геопространственная базовая модель, созданная НАСА и IBM [Jakubik et al., 2023; Li et al., 2024]. Prithvi решает задачи крупномасштабного анализа изображений, используя массивные наборы геопространственных данных, такие как согласованные снимки Landsat и Sentinel-2 (HLS). В отличие от традиционных моделей, Prithvi использует автономное обучение, что сокращает потребность в маркированных данных и позволяет проводить более масштабируемый анализ. Его приложения включают составление карт сельскохозяйственных культур, картографирование наводнений и прогнозирование лесных пожаров. Значимость Prithvi заключается в ее способности создавать эффективную и адаптируемую платформу для обработки крупномасштабных данных наблюдения Земли. Эта базовая геопространственная модель на основе трансформатора уменьшает потребность в данных с обширной маркировкой, тем самым ускоряя принятие решений в областях с ограниченным количеством маркированных геопространственных данных [Jakubik et al., 2023]. Однако обобщенный характер Prithvi может бороться с локальными явлениями без дальнейшей тонкой настройки. Например, точная классификация сельскохозяйственных культур на небольших сельскохозяйственных полях в странах Африки к югу от Сахары требует специальной корректировки из-за уникальных региональных различий и характеристик полей. Непрозрачность модели, которую часто называют «черным ящиком», затрудняет проверку достоверности и доверие заинтересованных сторон. Кроме того, большие вычислительные ресурсы, необходимые для обучения и обработки крупномасштабных данных, лимитируют доступность, особенно для учреждений с ограниченным бюджетом в развивающихся странах.

Другим заметным инструментом ГеоИИ, который привлекает к себе внимание, служит географическая модель сегментации любых объектов (Geographical Segment Anything Model – GeoSAM). GeoSAM – это усовершенствованная адаптация модели Segment Anything Model (SAM), разработанная специально для многоклассовой сегментации аэрофотоснимков или спутниковых изображений [Sultan et al., 2024]. Она автоматизирует процесс сегментации, используя разреженные и плотные запросы, что значительно повышает производительность по сравнению с традиционными моделями на основе CNN и ViT. Авторы работы [Sultan et al., 2024] протестировали модель, используя ортотрансформированные изображения высокого разрешения из Вашингтона (округ Колумбия) и Кембриджа (Массачусетс). Их результаты показали улучшение сегментации дорожной инфраструктуры на 26 % и улучшение сегментации пешеходной инфраструктуры на 7 %. Они рекомендуют провести дальнейшие исследования для дальнейшего повышения масштабируемости и применимости GeoSAM в различных геопространственных задачах и регионах. Несмотря на то что GeoSAM превосходит традиционные модели, ей трудно точно сегментировать узкие объекты, такие как дороги и тротуары, особенно когда их текстуры напоминают другие элементы изображения. Кроме того, помехи от окружающих объектов, таких как деревья, здания и транспортные средства, могут помешать модели создавать точные карты сегментации. Производительность модели снижается при применении к изображениям из разных регионов по сравнению с теми, которые использовались во время обучения. «Черный ящик» модели также затрудняет проверку достоверности и снижает уровень доверия заинтересованных сторон. Более того, зависимость GeoSAM от крупномасштабных вычислительных ресурсов, необходимых для обучения,

получения результатов и выводов, может ограничить ее доступность для конкретных пользователей или приложений.

Несмотря на то что ГеоИИ обладает значительными преимуществами, такими как обработка больших мультимодальных наборов данных и получение подробной геопространственной информации, он также сталкивается с трудностями. Эти проблемы включают проблемы интерпретируемости и объяснимости, присущие моделям машинного и глубокого обучения, трудности с воспроизводимостью в различных географических регионах и потенциальные этические проблемы, связанные с конфиденциальностью и справедливостью [Li et al., 2024]. Поскольку ГеоИИ становится инструментом обработки и анализа геопространственных данных, исследователи могут решать сложные проблемы окружающей среды в масштабах и на скоростях, превосходящих возможности человека. Однако эти расширенные возможности повышают потребность в прозрачности. Следовательно, заинтересованные стороны должны понимать причины, лежащие в основе решений, принимаемых с помощью этих мощных моделей ГеоИИ.

1.2. Почему в ГеоИИ важна объяснимость

Высокая производительность моделей машинного (ML) и глубокого (DL) обучения часто приводит к тому, что из-за их сложности их рассматривают как непрозрачные системы или «черные ящики». Например, метод случайного леса (Random Forest) и нейронные сети представляют собой типичные непрозрачные ML- и DL-модели. Методы объяснимого ИИ (XAI) предназначены для преобразования этих моделей «черного ящика» в более прозрачные модели «стеклянного ящика», предоставляя информацию о том, почему прогнозирующие факторы (предикторы) влияют на результат модели. Важность объяснимости в ГеоИИ усиливается при моделировании окружающей среды, где результаты могут влиять на политику и решения по управлению ресурсами в больших масштабах. Доверие к этим моделям искусственного интеллекта имеет решающее значение для обеспечения соблюдения этических норм в государственных секторах, таких как управление окружающей средой и здравоохранение, и для обеспечения того, чтобы решения основывались на разумной и объяснимой логике. Объяснимый ГеоИИ повышает прозрачность и подотчетность, позволяя заинтересованным сторонам понимать обоснование результатов ГеоИИ. Это имеет решающее значение для продвижения приложений ГеоИИ в картографировании растительного покрова, мониторинге запасов углерода в лесах, обеспечении готовности к стихийным бедствиям, изменении климата и других сценариях, где полезная информация должна быть точной и обоснованной.

Объяснимость особенно важна в геопространственных приложениях из-за особой природы пространственных данных, которые по своей сути связаны с местоположением и контекстом. В отличие от традиционных наборов данных, геопространственные данные часто зависят от пространственных связей и географических сложностей, таких как различия в рельефе, климате и т.д. Следовательно, модели машинного (ML) и глубокого (DL) обучения, применяемые для анализа геопространственных данных, должны учитывать эту пространственную динамику. Следовательно, объяснимость моделей ГеоИИ гарантирует, что решения отражают реальные пространственные сложности. Например, понимание того, как прогнозирующие факторы (предикторы) влияют на выходные данные модели, может помочь сделать прогнозы модели более информативными для заинтересованных сторон (ученых, лиц, принимающих решения, и служащих).

1.3. Методы объяснимого ИИ (XAI)

1.3.1. Обзор методов машинного (ML) и глубокого (DL) обучения

ГеоИИ использует различные методы искусственного интеллекта, такие как метод случайного леса (Random Forest), методы опорных векторов (Support Vector Machines – SVMs) и сверточные нейронные сети (Convolutional Neural Networks – CNNs). Исследователи успешно использовали эти методы для обработки геопространственных данных и извлечения значимой

информации и идей. Метод случайного леса (Random Forest) [Rodriguez-Galiano et al., 2012] и методы опорных векторов (SVMs) [Huang et al., 2002; Pal & Mather, 2005] широко используются для классификации растительного покрова благодаря их высокой способности моделировать нелинейные взаимосвязи. Эти модели классифицируют спутниковые снимки по типам растительного покрова на основе спектральных и текстурных особенностей. Однако одним из ограничений этих методов машинного обучения (ML) является то, что они требуют тщательной разработки функциональных возможностей для оптимизации производительности модели. Разработка функциональных возможностей часто требует знания предметной области для ручного создания функций, представляющих базовые закономерности в данных, что может занять много времени и привести к ошибкам.

В то же время сверточные нейронные сети (CNNs) получили широкое применение для извлечения пространственных объектов из спутниковых и аэрофотоснимков высокого разрешения [Yang et al., 2018]. В отличие от традиционных методов машинного обучения (ML), CNNs полностью устраняет необходимость в разработке объектов, что делает их более эффективными для сегментации и классификации сложных изображений. CNNs автоматически изучает пространственные иерархии объектов на основе необработанных входных данных, что позволяет фиксировать шаблоны и взаимосвязи, которые в противном случае было бы сложно спроектировать вручную. Эта возможность сделала CNNs особенно полезной в таких приложениях, как картографирование следов зданий, идентификация пород деревьев и извлечение других элементов ландшафта. Их способность автоматически определять объекты облегчила городское планирование, мониторинг инфраструктуры и управление окружающей средой, где решающее значение имеют подробные карты с высоким разрешением.

1.3.2. Обзор методов объяснимого ИИ (XAI)

Исследователи разработали несколько методов объяснимого ИИ (XAI) для решения проблем, связанных с «черным ящиком» и доверием к моделям искусственного интеллекта. Эти методы XAI в целом можно разделить на глобальные и локальные методы объяснения. Глобальные методы объяснения позволяют получить представление об общем поведении модели путем анализа всего набора данных. К таким методам относятся оценки важности признаков, графики частичной зависимости и глобальные суррогатные модели. Методы глобального объяснения дают ценную информацию об общем поведении модели, например, позволяют определить, какие прогнозирующие факторы (предикторы) оказывают наибольшее влияние на принятие решений. Например, в регрессионной модели высоты леса глобальные методы могут определять предикторные переменные (полосы Sentinel-2, спектральные индексы), влияющие на результат моделирования (рис. 1.1).

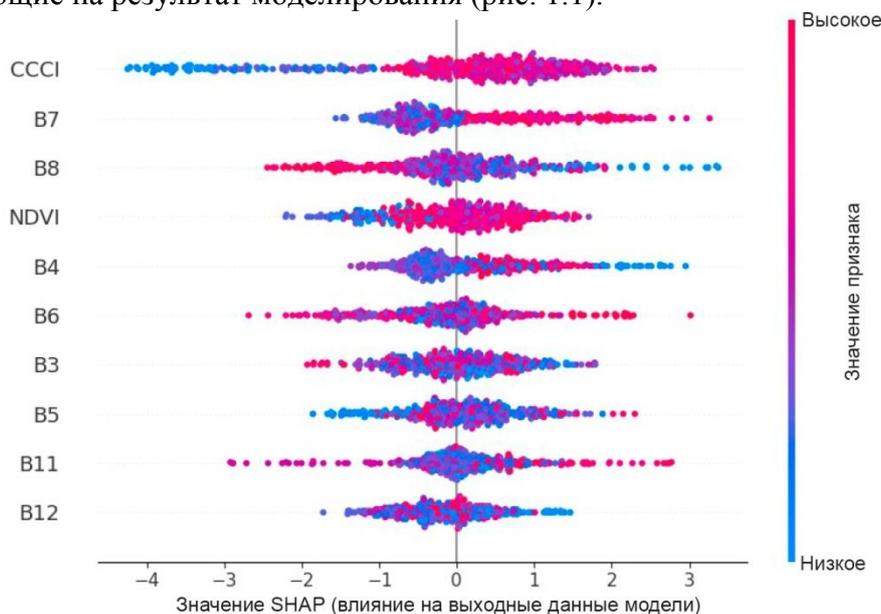


Рис. 1.1. Пример важности глобального элемента SHAP

Примечание переводчика. CCCI – индекс содержания хлорофилла в растительности, NDVI – нормализованный индекс растительности, Восемь спектральных диапазонов Sentinel-2: B3 – зеленый (GREEN), B4 – красный (RED), B5 – растительный красный крайний 1 (VRE 1), B6 – растительный красный крайний 2 (VRE 2), B7 – растительный красный крайний 3 (VRE 3), B8 – ближний инфракрасный (NIR), B11 – коротковолновый инфракрасный 1 (SWIR 1), B12 – коротковолновый инфракрасный 2 (SWIR 2).

В отличие от этого, методы локального объяснения направлены на то, чтобы обеспечить понимание индивидуальных прогнозов. Эти методы фокусируются на объяснении результата для конкретного случая, что делает их идеальными для интерпретации конкретных случаев. Например, местные методы объяснения, такие как аддитивные объяснения Шепли (SHAP) или не зависящие от модели локальные интерпретируемые объяснения (LIME), могут помочь определить, почему конкретный район был классифицирован как подверженный высокому риску наводнений, на основе таких факторов, как высота, уклон, растительный покров или структура почвы (рис. 1.2). Эта информация на местах особенно полезна для заинтересованных сторон, принимающих решения о конкретных местоположениях. Например, специалисты по планированию чрезвычайных ситуаций должны понимать основы классификации районов, подверженных стихийным бедствиям. Внедрение методов объяснимого ИИ (XAI) в приложения ГеоИИ имеет решающее значение для укрепления доверия и обеспечения подотчетности в процессах принятия решений. Предоставляя информацию о модельных прогнозирующих факторах (предикторах), эти методы позволяют заинтересованным сторонам лучше понимать модельные прогнозы.

Более того, методы объяснимого ИИ (XAI) также способствуют итеративному уточнению моделей. Разработчики могут выявлять потенциальные погрешности, уточнять выбор характеристик и повышать точность модели, понимая, какие переменные-предикторы влияют на прогнозы. Эта возможность имеет решающее значение в геопространственных контекстах, где различные факторы, такие как климат, топография и деятельность человека, взаимодействуют сложным образом. Таким образом, объяснимость способствует принятию обоснованных решений и играет жизненно важную роль в повышении надежности моделей ГеоИИ.

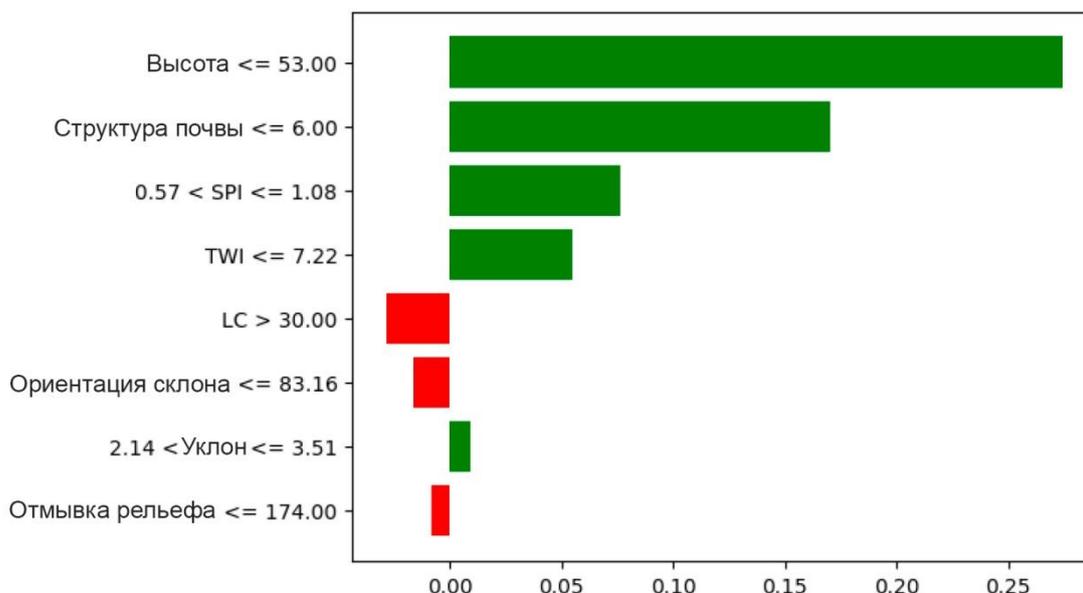


Рис. 1.2. График LIME, показывающий факторы, влияющие на составление карты подверженности наводнениям для конкретного случая

Примечание переводчика. SPI – индекс мощности потока (Stream Power Index), TWI – топографический индекс влажности ((Topographic Wetness Index), LC – наземный покров (Land Cover)

1.3.3. Методы объяснимого ИИ (XAI) для моделей ГеоИИ

Исследователи разработали различные методы искусственного интеллекта, некоторые из которых были применены в приложениях ГеоИИ. Методы объяснимого ИИ (XAI) предлагают различные объяснения в зависимости от модели и конкретного геопространственного приложения. В этом разделе мы кратко рассмотрим популярные методы объяснимого ИИ (XAI), такие как аддитивные объяснения Шепли (SHAP), не зависящие от модели локальные интерпретируемые объяснения (LIME), суррогатные модели дерева решений и градиентно-взвешенное отображение активации классов (Grad-CAM).

Аддитивные объяснения Шепли (SHAP) – один из наиболее широко используемых методов объяснимого ИИ (XAI), основанный на теории кооперативных игр [Shapley, 1953]. Значения SHAP дают локальные и глобальные объяснения, определяя вклад каждой функции в предсказание модели. В ГеоИИ SHAP может помочь объяснить, какие переменные-предикторы, такие как тип растительного покрова или высота над уровнем моря, влияют на прогнозы модели для составления карт риска наводнений или моделирования сокращения лесов. Одной из ключевых сильных сторон SHAP является ее согласованность и полнота. Это преимущество гарантирует, что сумма вкладов признаков соответствует результатам модели, обеспечивая точную разбивку того, как каждый признак влияет на прогноз. SHAP также не зависит от модели, а это означает, что его можно применять в различных моделях машинного (ML) и глубокого (DL) обучения, что делает его универсальным для различных приложений ГеоИИ.

Не зависящие от модели локальные интерпретируемые объяснения (LIME) – еще один популярный метод объяснимого ИИ (XAI) для объяснения индивидуальных прогнозов. Как правило, LIME аппроксимирует сложные модели более простыми и поддающимися интерпретации моделями. LIME работает, изменяя входные данные и наблюдая за результирующими изменениями в выходных данных модели, создавая локальную суррогатную модель, которую легче понять по сравнению с исходной сложной моделью. В моделях ГеоИИ LIME может использоваться для объяснения того, как различные предикторные переменные, такие как высота над уровнем моря или влажность почвы, влияют на решение модели в конкретном случае. Это делает LIME мощным инструментом для понимания индивидуальных, локализованных прогнозов. Однако недостаток LIME заключается в том, что его объяснения гарантированно будут верны только на местном уровне. В результате они могут плохо обобщать всю модель. Такое толкование может привести к недоразумениям, если оно будет интерпретировано вне предполагаемого объема.

Суррогатные модели дерева решений (рис. 1.3) – это еще один метод объяснимого ИИ (XAI), который позволяет аппроксимировать сложные модели с помощью более простых и понятных моделей дерева решений. Эти суррогатные модели созданы для имитации поведения более сложной модели, обеспечивая общее понимание того, как модель принимает свои решения. В приложениях ГеоИИ суррогаты дерева принятия решений могут дать представление о том, как переменные-предикторы, такие как полосы частот Sentinel-2, спектральные индексы и высота над уровнем моря, влияют на прогнозы на более широком уровне. Однако, как и в случае с LIME, суррогатные модели могут чрезмерно упрощать сложные взаимосвязи и, следовательно, не отражать все детали поведения исходной модели.

Градиентно-взвешенное отображение активации классов (Grad-CAM) – это метод визуального объяснения, специально разработанный для моделей глубокого обучения (DL) [Selvaraju et al., 2017], в частности сверточных нейронных сетей (CNNs). Grad-CAM создает тепловые карты, которые визуально отображают, какие области входного изображения оказали наибольшее влияние на процесс принятия решений моделью. Например, Grad-CAM может выделить те части спутникового изображения, которые в наибольшей степени повлияли на классификацию региона как городского, водного или лесного. Эти наглядные пояснения очень ценны для экспертов в предметной области и заинтересованных сторон, поскольку позволяют интуитивно понять, почему модель была отнесена к той или иной классификации. Таким

образом, визуализация повышает уверенность в процессе принятия решений. Однако Grad-CAM предназначен только для сверточных нейронных сетей (CNNs) и не применяется к другим моделям глубокого обучения (DL).

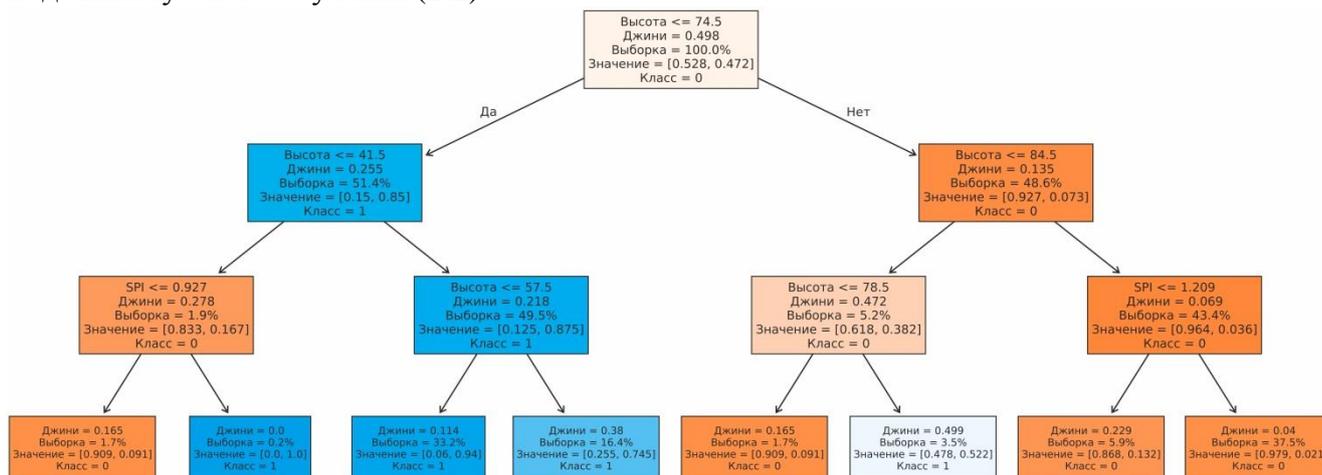


Рис. 1.3. Пример суррогатной модели дерева принятия решений

1.4. Применение объяснимого ГеоИИ для моделирования окружающей среды

Объяснимый ГеоИИ обладает огромным потенциалом для повышения надежности и прозрачности моделей ГеоИИ при моделировании окружающей среды. Повышая объяснимость этих моделей, объяснимый ГеоИИ гарантирует, что полученные аналитические данные будут достоверными, понятными и доступными для заинтересованных сторон. Использование ГеоИИ укрепляет доверие и облегчает принятие обоснованных решений. В этой книге рассмотрены два ключевых тематических исследования, демонстрирующих преимущества объяснимого ГеоИИ путем моделирования структуры лесов и составления карт затопления во время наводнений.

Первое тематическое исследование посвящено моделированию структуры дикорастущих лесов с использованием модели случайного леса (Random Forest) в сочетании с данными наблюдения Земли (Earth observation – EO) (космический лидар, снимки Sentinel-2). Цель состоит в том, чтобы смоделировать высоту лесного покрова – важнейший показатель для мониторинга биоразнообразия, связывания углерода и общего состояния лесов. Применяя SHAP, мы стремимся определить, какие переменные-предикторы существенно влияют на прогнозы высоты лесного покрова. Этот уровень понимания особенно ценен для ученых, стремящихся усовершенствовать модели прогнозирования высоты древесного покрова. Это также приносит пользу другим заинтересованным сторонам, которые стремятся понять, как различные предикторы влияют на результат модели.

Применение объяснимого ГеоИИ наиболее важно в моделировании окружающей среды, где прозрачность имеет решающее значение для разработки политики и управления ресурсами. Например, моделирование структуры дикорастущих лесов с использованием модели случайных лесов (Random Forest) в сочетании с SHAP может помочь определить ключевые факторы, влияющие на высоту полого леса, что способствует планированию природоохранных мероприятий. Аналогичным образом, картографирование наводнений с использованием модели U-Net совместно с Grad-CAM помогает визуализировать, какие части изображений повлияли на классификацию затопленных районов, поддерживая информированное управление в случае стихийных бедствий. Объяснимый ГеоИИ повышает доверие к передовым технологиям машинного и глубокого обучения, предлагая четкое понимание геопространственных моделей, управляемых искусственным интеллектом. Включение объяснимости в модели ГеоИИ делает их мощным инструментом устойчивого управления окружающей средой.

1.5. Краткие итоги

ГеоИИ интегрирует искусственный интеллект с пространственными данными, наукой и геопространственными технологиями для решения пространственных задач и улучшения понимания. Эта область быстро развивается благодаря достижениям в области технологий искусственного интеллекта, в частности машинного (ML) и глубокого обучения (DL), а также растущей доступности геопространственных данных. ГеоИИ применяется в различных областях, включая картографирование растительного покрова, мониторинг сокращения лесов, городское планирование и моделирование климата. Однако из-за присущей моделям машинного (ML) и глубокого обучения (DL) сложности они часто рассматриваются как «черные ящики», что может препятствовать их внедрению, особенно в таких чувствительных областях, как управление окружающей средой и здравоохранение. Это создает острую потребность в объяснимых методах искусственного интеллекта (ХАИ) для повышения прозрачности моделей и доверия заинтересованных сторон.

Объяснимый ГеоИИ использует методы искусственного интеллекта, такие как SHAP, LIME, суррогатные модели дерева решений и Grad-CAM, для объяснения поведения глобальных и локальных моделей. Эти методы помогают заинтересованным сторонам понять, что предсказывает модель и почему она делает эти прогнозы. Например, атрибуты SHAP определяют вклад в предсказание модели, в то время как LIME аппроксимирует сложные модели более простыми для объяснения отдельных предсказаний. Grad-CAM особенно полезен для визуализации того, какие области входных изображений повлияли на классификационные решения модели, что делает его идеальным для моделей глубокого обучения (DL), таких как сверточные нейронные сети (CNNs).

Объяснимый ГеоИИ имеет важное применение в моделировании окружающей среды, где прозрачность играет решающую роль при разработке политики и управлении ресурсами. Например, моделирование структуры дикорастущих лесов в сочетании с SHAP может помочь определить ключевые факторы, влияющие на высоту полого леса, что способствует планированию природоохранных мероприятий. Аналогичным образом, картографирование наводнений с использованием модели U-Net совместно с Grad-CAM помогает визуализировать, какие части изображений повлияли на классификацию затопленных районов, поддерживая информированное управление в случае стихийных бедствий. Объяснимый ГеоИИ повышает доверие к передовым технологиям машинного и глубокого обучения, предлагая четкое понимание геопространственных моделей, управляемых искусственным интеллектом. Включение объяснимости в модели ГеоИИ делает их мощным инструментом устойчивого управления окружающей средой.

Глава 2. Практический пример 1: Объяснимое машинное обучение для моделирования структуры леса

2.1. Введение

В главе используется метод случайного леса (Random Forest) для моделирования высоты лесного покрова, основанный на наблюдениях НАСА по исследованию глобальной динамики экосистем (Global Ecosystem Dynamics Investigation – GEDI) и спутниковых данных Sentinel-2. Продукт GEDI уровня 2A с геолокацией и показателями высоты (GEDI02_A) и данные Sentinel-2 доступны в Google Earth Engine (GEE). Набор данных GEDI уровня 2A содержит различные показатели, относящиеся к вертикальной структуре растительности, такие как высота полого [Dubayah et al., 2020]. Этот набор данных включает показатели относительной высоты (RH), которые представляют высоту при заданном квантиле энергии (в диапазоне от 1-го до 100-го) относительно высоты самого низкого режима формы сигнала, что указывает на уровень земной поверхности [Hofton & Blair, 2019; Potapov et al., 2021]. В этой книге мы используем RH98 для представления высоты верхнего купола, поскольку он считается более надежным и менее

чувствительным к шуму показателем, чем RH100 [Milenković et al., 2022; Li et al., 2023]. На рис. 2.1 показаны данные о следах GEDI уровня 2А, наложенные на снимки Sentinel-2.

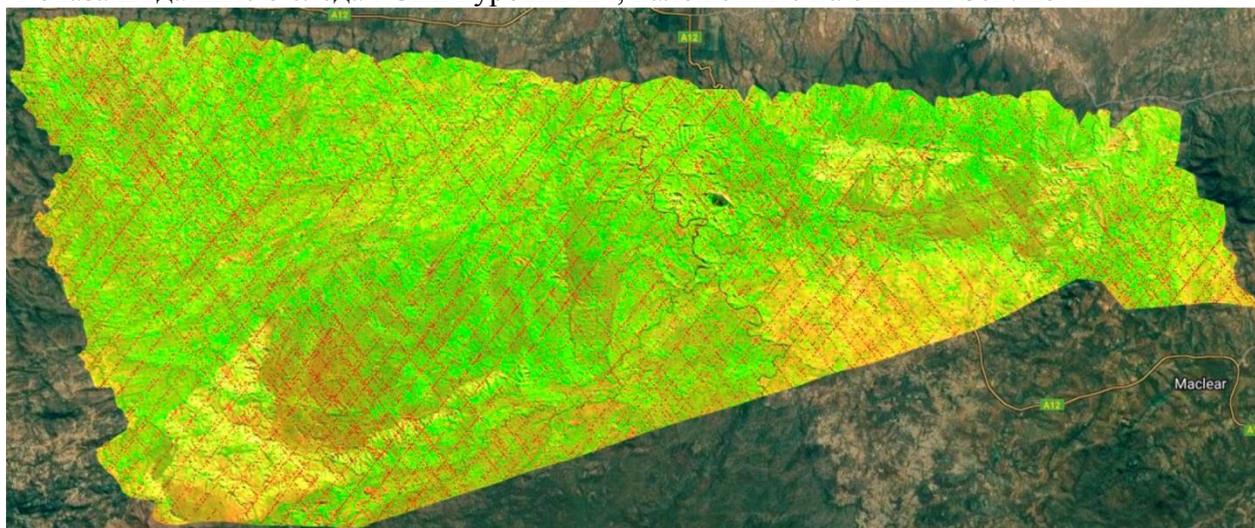


Рис. 2.1. Данные о следах GEDI уровня 2 (красные линии), наложенные на снимки Sentinel-2 в заповедной зоне Мавурадонха, Зимбабве

В главе используются восемь спектральных диапазонов Sentinel-2, нормализованный индекс растительности (Normalized Difference Vegetation Index – NDVI) и индекс содержания хлорофилла в древесном пологом (Canopy Chlorophyll Content Index – CCCI). Эти спектральные индексы, широко используемые в дистанционном зондировании, играют важную роль в мониторинге здоровья, силы и продуктивности растительности. NDVI, в частности, является наиболее часто используемым показателем для оценки состояния растительности. Он измеряет разницу между ближним инфракрасным (Near-Infrared – NIR) и красным (RED) диапазонами. Более высокие значения NDVI обычно указывают на здоровую зеленую растительность, поскольку здоровые растения хорошо отражают ближний инфракрасный (NIR) и поглощают красный (RED) свет. И наоборот, более низкие значения NDVI указывают на стрессовую ситуацию с растительностью или на землю без растительного покрова. NDVI рассчитывается следующим образом:

$$NDVI = \frac{NIR - RED}{NIR + RED}.$$

Примечание переводчика. Комбинации каналов, используемые для расчета NDVI:

- для спутников Landsat канал 3 видимый красный (RED) 0,630–0,690 нм и канал 4 ближний инфракрасный (NIR) 770–900 нм;
- для спутников Sentinel-2 канал B4 видимый красный (RED) 0,640–0,670 нм и канал B5 ближний инфракрасный (NIR) 840–880 нм;
- для спутников MODIS канал 2 видимый красный (RED) 0,620–0,670 нм и канал 4 ближний инфракрасный (NIR) 840–880 нм;
- для спутников Landsat-8 канал 3 видимый красный (RED) 0,630–0,690 нм и канал 8А ближний инфракрасный (NIR) 750–900 нм.

Индекс содержания хлорофилла CCCI представляет собой более специализированный по сравнению с NDVI показатель для оценки содержания хлорофилла в растительных покровах. Содержание хлорофилла является важнейшим показателем для оценки здоровья и продуктивности растительности. Одно из ключевых преимуществ CCCI – использование диапазона красного крайнего (Red Edge – RE), который чувствителен к изменениям содержания хлорофилла. Таким образом, CCCI позволяет выявлять мелкие изменения концентрации хлорофилла, обеспечивая более детальное представление об условиях вегетации. CCCI рассчитывается следующим образом:

$$CCCI = \frac{NIR - RE}{NIR + RE} / \frac{NIR - RED}{NIR + RED}.$$

2.2. Предварительный анализ данных

2.2.1. Данные о высоте полога леса GEDI

Прямоугольные диаграммы и графики плотности показывают распределение высоты полога леса на уровне 2A в GEDI в пределах заповедной зоны Мавурадонха (рис. 2.2). Леса и луга миомбо (преобладающее растительное сообщество в Центральной Африке) в основном покрывают охраняемую территорию. Однако недавний рост активности человека, такой как вырубка деревьев, сельское хозяйство и добыча полезных ископаемых, представляет серьезную угрозу целостности этой экосистемы. На прямоугольном графике средняя высота полога леса составляет приблизительно от 7 до 15 м, что соответствует ожидаемой высоте полога в лесах миомбо, которая обычно колеблется от 7 до 20 м. Межквартильный диапазон (IQR), который представляет собой средние 50 % данных о высоте полога, также находится в пределах этого ожидаемого диапазона, что указывает на то, что значительная часть высоты полога остается типичной для ненарушенных лесов миомбо. Однако на графике также видны отклонения, превышающие 25 м. Эти отклонения могут неточно отражать фактическую высоту полога и могут быть вызваны ошибками измерений. Из-за большой возвышенности и крутых склонов района заповедной зоны Мавурадонха датчик GEDI, возможно, переоценил высоту древесного покрова, что привело к появлению этих аномалий.

График плотности также показывает, что распределение крон по высоте имеет прямой перекосяк, причем высота многих крон колеблется от 5 до 15 м. Пик плотности на более низких высотах полога леса указывает на то, что в регионе наблюдается некоторый уровень деградации лесов, особенно в районах, где деятельность человека затронула естественные лесные зоны. График плотности также показывает длинный хвост, простирающийся более чем на 30 м, хотя такие большие значения высоты полога леса встречаются реже. Это указывает на наличие артефакта, связанного с неточностями измерений на возвышенностях.

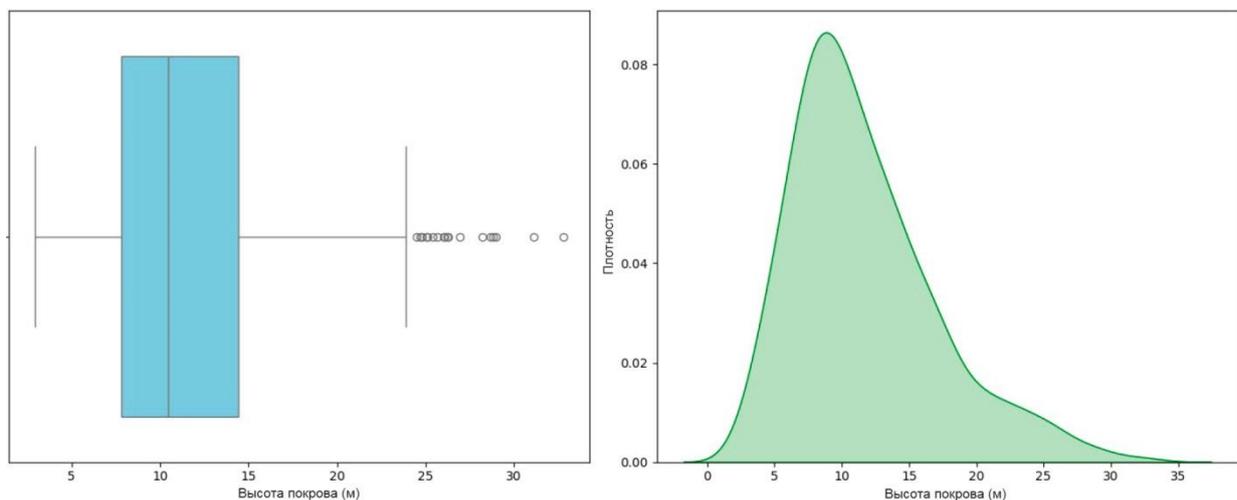


Рис. 2.2. Распределение высоты крон деревьев GEDI в районе исследования

Таким образом, графики показывают, что, хотя большая часть распределения высоты лесного покрова остается в пределах ожидаемого диапазона для лесов миомбо, налицо явные признаки нарушения, вероятно, вызванного вторжением человека и сельскохозяйственной деятельностью. Кроме того, наблюдаемые на графиках выбросы и «длинный хвост» могут быть вызваны завышением показаний датчика GEDI, особенно в районах с большой высотой и крутыми склонами. Эти наблюдения подчеркивают необходимость тщательной интерпретации лидарных данных на таких участках.

2.2.2. Анализ спектральной отражательной способности с использованием прямоугольных диаграмм

На рис. 2.3 показано распределение значений спектральной отражательной способности для восьми спектральных диапазонов Sentinel-2, а именно: B3 (зеленый), B4 (красный), B5 (растительный красный крайний 1), B6 (растительный красный крайний 2), B7 (растительный красный крайний 3), B8 (ближний инфракрасный), B11 (коротковолновый инфракрасный 1) и B12 (коротковолновый инфракрасный 2), наряду с CCCI и NDVI. На графике представлены ключевые статистические показатели, такие как медиана, межквартильный диапазон и выбросы, позволяющие получить представление об изменчивости спектральной отражательной способности на разных длинах волн. Медианные значения и наличие отклонений имеют значение при интерпретации этих распределений.

Для диапазонов с B3 по B5 средний спектральный коэффициент отражения обычно составляет менее 0,4, что соответствует типичному коэффициенту отражения растительности в этих частях электромагнитного спектра. В частности, для спектральных диапазонов B3 (зеленый) и B4 (красный) коэффициенты ниже, вероятно, из-за их чувствительности к поглощению хлорофилла. Это приводит к снижению коэффициента отражения для здоровой растительности. На графиках также видно, что эти полосы имеют многочисленные выбросы, что указывает на определенную степень неоднородности спектральной отражательной способности. Диапазон B5 (VRE1) также имеет среднее значение ниже 0,4, что немного выше, чем диапазоны B3 и B4. Более высокое среднее значение в диапазоне красного крайнего (RE) имеет большое значение, поскольку этот диапазон часто используются для определения изменений в состоянии растительности и уровня стресса. Диапазон красного крайнего (RE), расположенный между красным (RED) и ближним инфракрасным (NIR) диапазонами, показывает быстрое увеличение коэффициента отражения, вызванное поглощением хлорофилла и отражением структуры листьев. Эта характеристика объясняет, почему медиана B5 выше, чем в диапазонах B3 и B4.

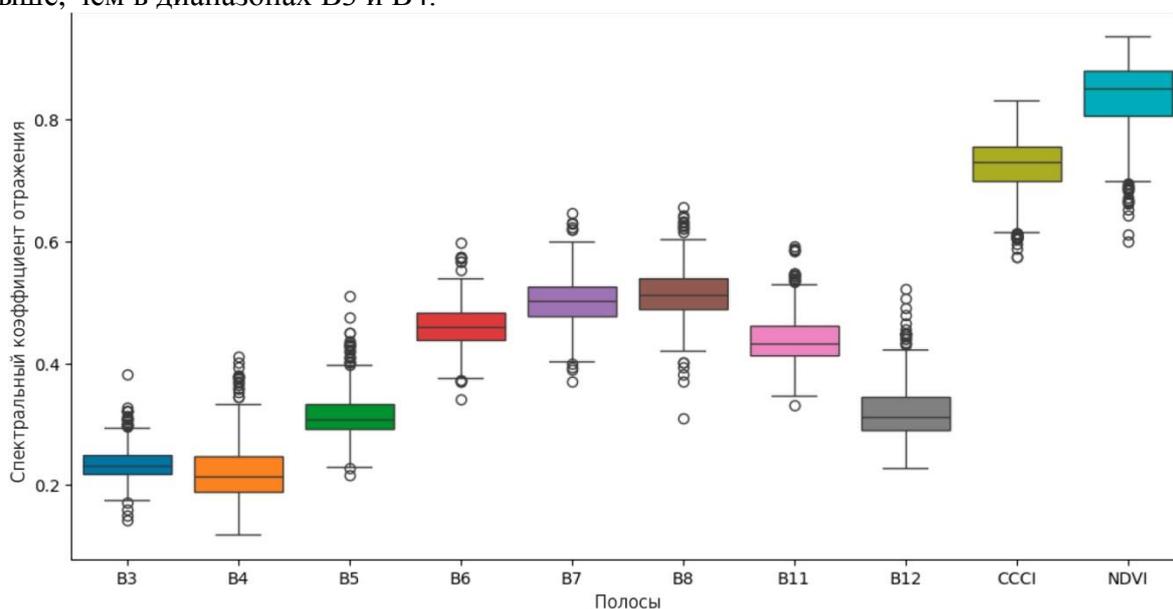


Рис. 2.3. Прямоугольная диаграмма, показывающая распределение значений спектральной отражательной способности Sentinel-2

При переходе к диапазонам B6 (VRE 2), B7 (VRE 3) и B8 (NIR) наблюдается постепенное увеличение средней спектральной отражательной способности. Диапазон B8 (NIR) показывает несколько более высокие значения спектральной отражательной способности. Это характерно для здоровой растительности, которая хорошо отражает ближний инфракрасный свет, что способствует повышению коэффициента отражения в этом диапазоне. Среднее значение для диапазона B8 превышает 0,5, что указывает на высокий коэффициент отражения в ближнем инфракрасном диапазоне. Диапазоны B6 и 7 также демонстрируют умеренное

увеличение среднего коэффициента отражения по сравнению с диапазонами В3 – В5, что отражает их роль в улавливании незначительных изменений содержания хлорофилла. Диапазоны В11 (SWIR 1) и В12 (SWIR 2) показывают более низкую среднюю спектральную отражательную способность, чем ближний инфракрасный диапазон В8 (NIR). Эти диапазоны чувствительны к содержанию влаги в растительности и почве, и их более низкая отражательная способность указывает на различные уровни влажности в ландшафте.

Наконец, NDVI и CCCI показывают более высокие медианные значения. NDVI показывает высокое среднее значение, что указывает на общую здоровую растительность в исследуемой зоне. CCCI, который включает красный край (Red Edge – RE), также показывает высокое среднее значение и, по-видимому, отражает более тонкие колебания содержания хлорофилла. Как правило, NDVI и CCCI коррелируют с растительным покровом и биомассой в большей степени, чем только диапазоны видимый красный В4 (RED) или ближний инфракрасный В8 (NIR).

2.2.3. Анализ спектральной отражательной способности с использованием графиков плотности

На рис. 2.4 показано распределение значений спектральной отражательной способности для восьми спектральных диапазонов Sentinel-2. Мы наблюдаем, что спектральный коэффициент отражения в основном находится в диапазоне от 0,15 до 0,3 для В3 и от 0,1 до 0,35 для В4, с пиками приблизительно на уровне 0,2. Это типично для растительности, которая отражает умеренное количество зеленого света, поглощая при этом значительное количество красного. Узкие пики и относительно низкие значения максимального коэффициента отражения указывают на то, что растительный покров доминирует в этих наблюдениях.

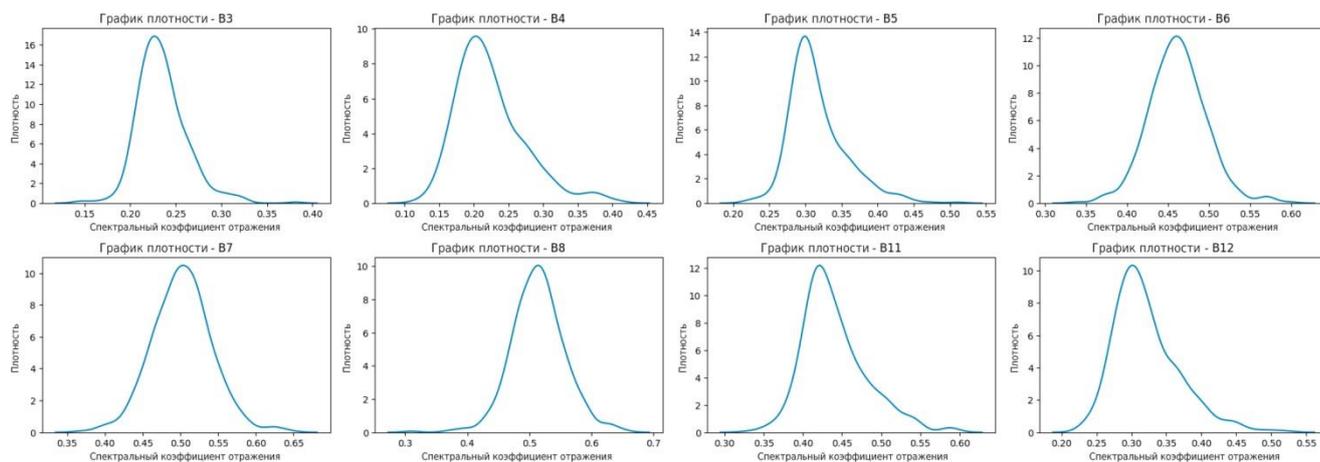


Рис. 2.4. График плотности, показывающий распределение значений спектральной отражательной способности для диапазонов Sentinel-2

Мы наблюдаем сдвиг в сторону более высоких значений коэффициента отражения для диапазонов В5, В6 и В7. В частности, В5 (VRE 1) имеет пик около 0,3, в то время как диапазоны В6 (VRE 2) и В7 (VRE 3) имеют более высокие пики около 0,45 и 0,5 соответственно. Диапазон красного крайнего (Red Edge – RE) чувствителен к изменениям содержания хлорофилла и предоставляет важную информацию о состоянии растений и стрессовых ситуациях. Более высокое и широкое распределение коэффициента отражения указывает на характерную реакцию здоровой растительности в области красного крайнего (RE), которая отражает больше по мере увеличения содержания хлорофилла.

Диапазон 8 (NIR) показывает четкий пик на уровне около 0,5, что указывает на высокую отражательную способность. Здоровая растительность хорошо отражает ближний инфракрасный свет благодаря внутренней структуре листьев, поэтому пик значительно выше

видимых диапазонов. Более высокая плотность при этих уровнях отражения означает наличие здоровой зеленой растительности в наблюдаемых данных.

Для диапазонов B11 (SWIR 1) и B12 (SWIR 2) максимумы наблюдаются на уровне приблизительно 0,45 и около 0,3 соответственно. Диапазоны коротковолнового инфракрасного (SWIR) чувствительны к содержанию воды в растительности и почве. Таким образом, более низкие значения спектрального коэффициента отражения соответствуют роли SWIR в определении уровня влажности. Диапазон B11 показывает относительно высокую плотность пиков, что свидетельствует об умеренном коэффициенте отражения, указывающем на изменение влажности на поверхности растительности и почвы. Напротив, диапазон B12 показывает более широкое распределение значений коэффициента отражения, на которые, возможно, влияют колебания уровня воды и состояния почвы. В целом, эти графики плотности дают представление о том, как различные длины волн взаимодействуют с растительностью и почвой. Каждый диапазон содержит уникальную информацию для мониторинга состояния растений, стресса и содержания влаги.

2.3. Оценка эффективности модели

Мы применили метод перекрестной проверки с 10-кратным коэффициентом ($cv=10$) для оценки точности прогнозирования регрессивной модели случайного леса (Random Forest Regression – RMSE). На рис. 2.5 оценки RMSE варьируются примерно от 5 до 6 м на разных итерациях, что подчеркивает изменчивость производительности модели. В частности, некоторые итерации демонстрируют относительно низкие значения RMSE, около 5 м, что указывает на более высокую точность прогнозирования и меньшее количество ошибок модели. И наоборот, другие итерации демонстрируют более высокие значения RMSE, примерно 6 м. Это говорит о том, что модель допускала более значительные ошибки прогнозирования. Самые низкие значения RMSE для моделей 6 и 7 указывают на то, что эти конкретные итерации обеспечили более надежные и точные прогнозы. В то же время самые высокие значения RMSE зафиксированы для моделей 3 и 9, что указывает на случаи, когда производительность модели была неоптимальной, а частота ошибок высокой. Эта изменчивость указывает на то, что прогнозируемая производительность модели меняется на разных итерациях. Характеристики данных, настройки модели и различия в разделениях на обучение и тестирование во время перекрестной проверки способствуют возникновению этой несогласованности.

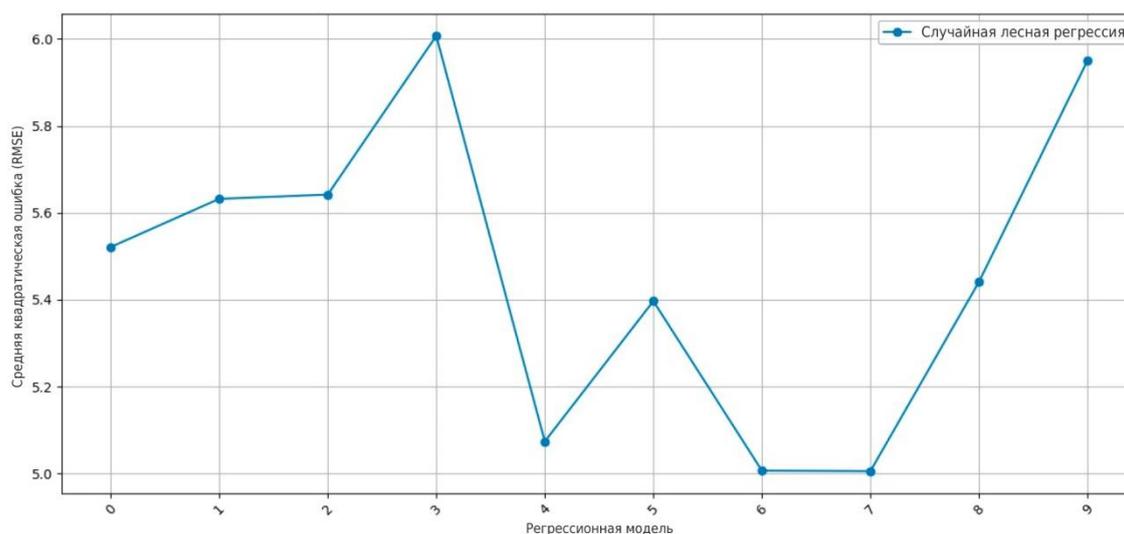


Рис. 2.5. Результаты RMSE для регрессионной модели случайного леса (Random Forest Regression) после 10-кратной перекрестной проверки

Рекомендуется дальнейшее уточнение модели для достижения более согласованного и низкого RMSE на всех итерациях. Это несоответствие указывает на необходимость усовершенствований, таких как улучшенная настройка гиперпараметров для оптимизации параметров модели или более эффективная предварительная обработка данных для

обеспечения надежной производительности. Учет этих аспектов может помочь стабилизировать точность прогнозирования модели, тем самым достигая более надежных и обобщенных результатов на всех этапах процесса перекрестной проверки. В конечном счете, цель состояла бы в уменьшении вариабельности и последовательном достижении более низких значений RMSE, что могло указывать на повышение общей производительности модели.

На рис. 2.6 показан точечный график, отображающий зависимость между эталонной высотой полога леса GEDI и расчетной высотой. Линия регрессии, характеризуемая $y=0,04x+11,29$, указывает на слабую положительную линейную зависимость между исходной и расчетной высотами крон деревьев. График показывает несколько проблем с прогнозированием модели. Обратите внимание, что точки данных сильно разбросаны по линии регрессии, что указывает на существенную несогласованность в прогнозах модели.

Другим важным замечанием является погрешность, присутствующая в оценке. Значение пересечения, равное 11,29, означает, что модель предсказывает высоту около 11,29 м, даже когда исходная высота приближается к нулю. Это постоянное завышение особенно заметно при более низких исходных высотах крон деревьев, что позволяет предположить, что модель систематически завышает высоту при низких исходных значениях. Это может привести к неточным выводам. В работе [Li et al., 2023] отмечено, что GEDI хорошо зарекомендовал себя на деревьях высотой от 3 до 15 м в лесах африканской саванны. Однако GEDI был менее надежен при высоте кроны ниже 2,34 м из-за ограничений по ширине импульса, что делало его непригодным для оценки высоты кустарников.

Влияние выбросов (рис. 2.6) очевидно на точечной диаграмме, поскольку они способствуют слабой корреляции и искажают точность прогнозов модели случайного леса (Random Forest). Увеличенный разброс точек данных, особенно на предельных значениях базового диапазона высот, указывает на то, что эти отклонения негативно сказались на способности модели к обобщению. В результате модель не может обеспечить точные оценки для различных значений высоты. Следовательно, для повышения производительности модели необходимо выполнить очистку данных путем обнаружения и удаления выбросов. В частности, крайне важно анализировать и корректировать высоту крон деревьев GEDI, особенно в районах с большими возвышенностями или крутыми склонами, которые, как известно, приводят к неточностям в лидарных измерениях. Кроме того, также важно скорректировать параметры модели, чтобы свести к минимуму влияние выбросов.

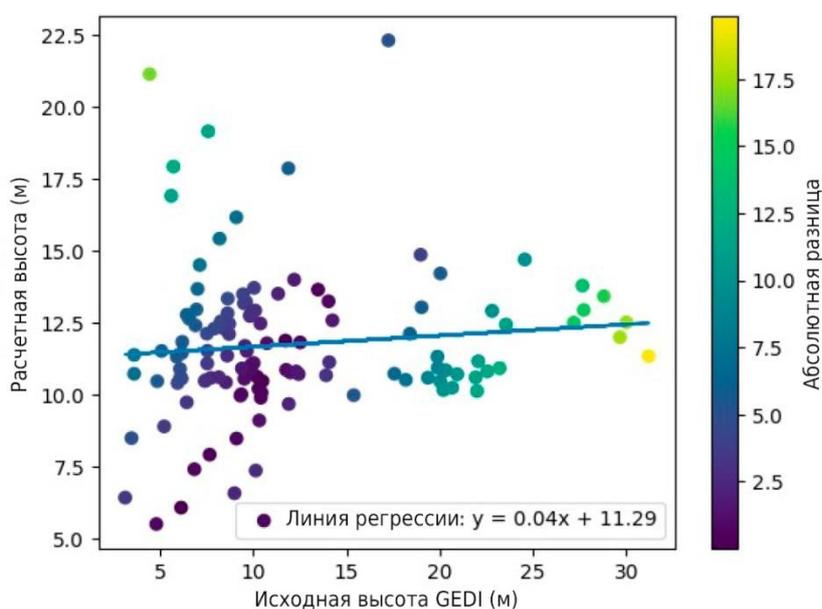


Рис. 2.6. Соотношение между контрольной высотой полога леса GEDI и расчетной высотой

Абсолютная разница между исходной и расчетной высотой крон деревьев позволяет получить более полное представление о точности прогнозов модели. Темные (фиолетовые) точки указывают на меньшие абсолютные различия, что означает более точные прогнозы, в то время как светлые (желтые) точки указывают на большие расхождения между исходной и расчетной высотой кроны. Светлые точки чаще встречаются при больших исходных высотах кроны, значит модель с трудом может точно предсказать высоту деревьев. Это вызывает особую озабоченность, поскольку можно предположить, что производительность модели снижается с увеличением высоты лесного покрова, что потенциально ограничивает ее эффективность при оценке высоты зрелых лесов.

Наконец, распределение точек показывает закономерность в разбросе прогнозов. Большинство расчетных высот находятся в диапазоне от 10 до 15 м, независимо от исходной высоты кроны. Такая кластеризация подчеркивает тенденцию модели к прогнозированию в узком диапазоне, что отражает ее неспособность адекватно отразить изменчивость при больших исходных высотах кроны. Это ограничение еще больше ухудшает производительность модели, особенно для высоких деревьев или сложных структур кроны.

Модель, как правило, демонстрирует слабую линейную зависимость между исходными и расчетными высотами кроны деревьев, постоянное завышение при более низких исходных значениях и значительную неточность при более высоких исходных высотах. Абсолютные различия, обозначенные цветом, подчеркивают трудности модели в прогнозировании высоты кроны с высокой точностью. Кроме того, кластеризация прогнозов в узком диапазоне демонстрирует ограниченную способность модели реагировать на изменения в исходных данных. Решение этих проблем требует очистки данных, тщательной настройки модели и использования дополнительных предикторов для лучшего учета сложности, лежащей в основе данных о высоте кроны. На рис. 2.7 показана прогнозируемая высота лесного покрова.

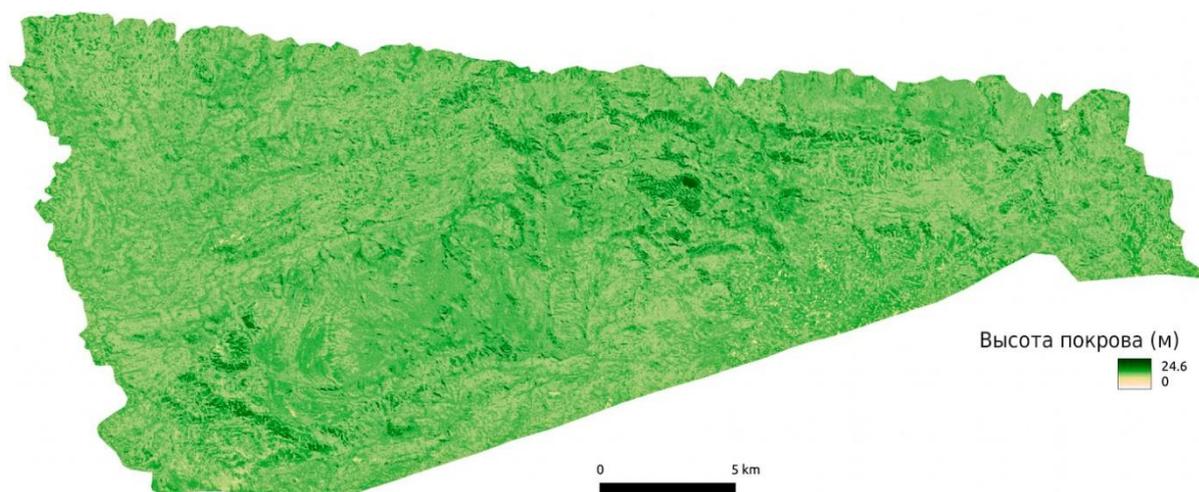


Рис. 2.7. Прогнозируемая высота лесного покрова

2.4. Интерпретация значений SHAP

2.4.1. Интерпретация глобальных значений SHAP

Анализ важности объектов с использованием SHAP

На рис. 2.8 показан график важности признака, который использует глобальные значения SHAP для объяснения вклада каждого диапазона Sentinel-2, и спектральных индексов в предсказаниях модели. На графике показаны средние абсолютные значения SHAP для каждого предиктора, отражающие среднее влияние каждого предиктора на выходные данные модели.

Этот тип анализа полезен для понимания того, какие предикторные переменные оказывают наибольшее влияние на предсказания модели, что позволяет получить представление о вкладе предикторов в регрессионную модель.

На рис. 2.8 показано, что CCCI имеет самое высокое среднее значение SHAP, что указывает на то, что он оказывает наиболее существенное влияние на прогнозы модели. Это говорит о том, что CCCI играет жизненно важную роль в объяснении изменения целевой переменной. Его эффективность, вероятно, обусловлена его чувствительностью к состоянию растительности и уровню хлорофилла. NDVI является вторым по значимости прогностическим фактором после CCCI, хотя его влияние заметно меньше по сравнению с CCCI.

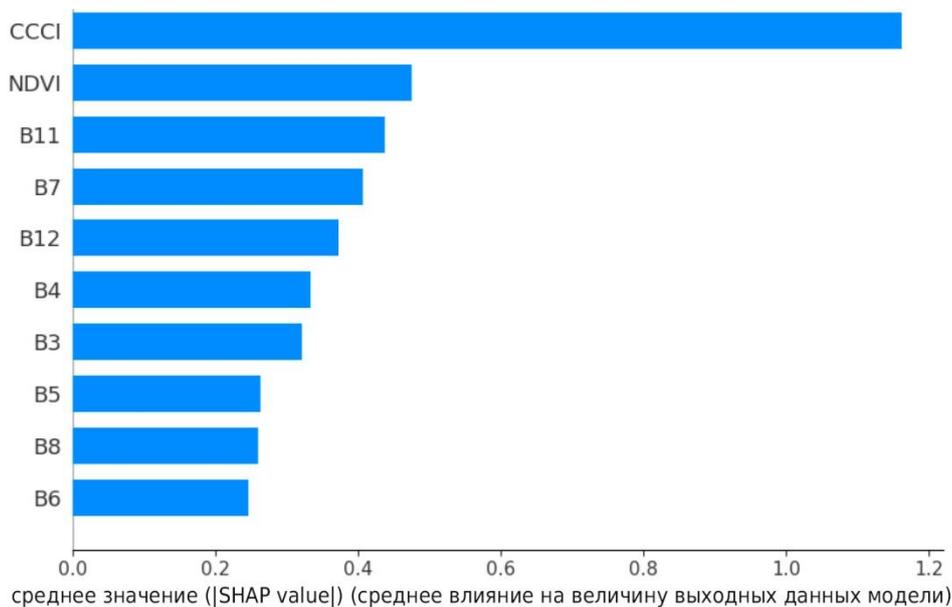


Рис. 2.8. Средние значения SHAP, представляющие важность признака для диапазонов Sentinel-2 и спектральных индексов

Среди спектральных диапазонов Sentinel-2 наиболее впечатляющими являются B11 (SWIR 1), B7 (VRE 3) и B12 (SWIR 2) с относительно высокими средними значениями SHAP. Это подчеркивает их важность для сбора информации, связанной с содержанием влаги в почве и растительности, а также с незначительными изменениями содержания хлорофилла в диапазоне красного крайнего (Red Edge – RE). Напротив, диапазоны B6 (VRE 2) и B8 (NIR) оказывают наименьшее влияние на предсказания модели, о чем свидетельствуют их более низкие средние значения SHAP. Следовательно, эти диапазоны в меньшей степени влияют на общую объясняющую способность модели.

График важности признаков, полученный на основе значений SHAP, помогает определить наиболее важные предикторы, определяющие точность модели, предоставляя ценную информацию для понимания поведения модели. Однако важно отметить, что этот анализ не предоставляет информации о направлении влияния – о том, вносит ли каждый предиктор положительный или отрицательный вклад в прогнозы. Вместо этого он предоставляет только уровень влияния каждого предиктора. Поэтому требуется дальнейший анализ, чтобы понять, как конкретно изменения в этих характеристиках влияют на предсказания модели.

Анализ распределения значений SHAP с использованием графика пчелиный рой

На рис. 2.9 показан график пчелиный рой, полученный с использованием значений SHAP. График пчелиный рой показывает основное распределение данных, избегая при этом

наложения между отдельными точками. График пчелиный рой показывает подробное представление о том, как вклад отдельных предикторов изменяется во всех прогнозах, сделанных с помощью модели. Каждая точка на графике пчелиный рой представляет собой отдельный прогноз, при этом цвет точки указывает на значение признака – красный для высоких значений признака и синий для низких значений признака. Эта визуализация позволяет нам наблюдать влияние каждого предиктора на выходные данные модели, выявляя как величину, так и направление влияния.

Индекс содержания хлорофилла в лесном покрове (СССИ) оказывает наиболее существенное влияние на выходные данные модели. Высокие значения ССССИ, обозначенные красными точками, в целом подтверждают прогнозы модели, предполагая, что повышенное содержание хлорофилла приводит к более высоким прогнозам для целевой переменной. И наоборот, низкие значения ССССИ, показанные синим цветом, как правило, снижают прогнозы, что указывает на негативное влияние на результаты моделирования. Это подчеркивает, что ССССИ является сильным фактором, определяющим прогнозы модели, с четкими и последовательными закономерностями, зависящими от значения этого признака.

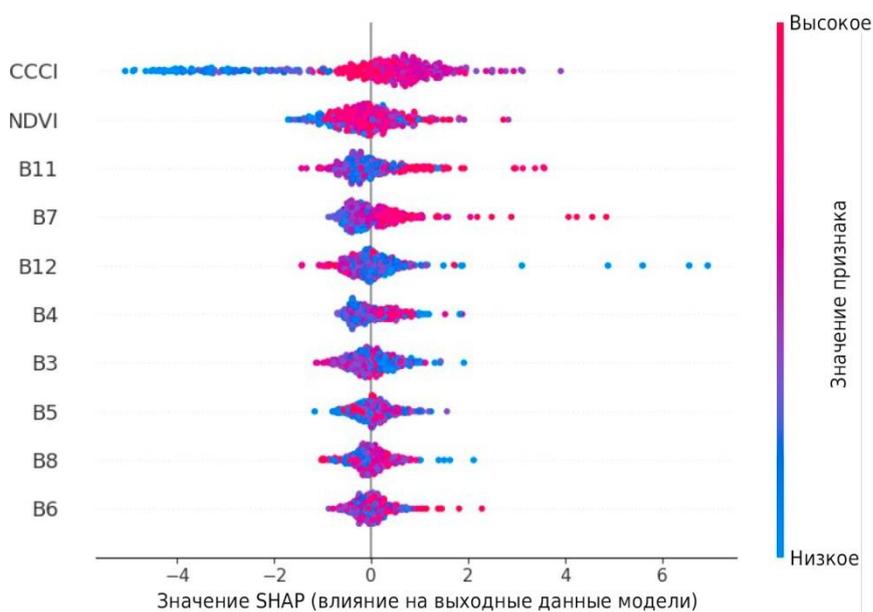


Рис. 2.9. График SHAP пчелиный рой, иллюстрирующий влияние значения признака на предсказания модели

Аналогичная картина наблюдается для NDVI и других диапазонов Sentinel-2, хотя их общее влияние менее выражено по сравнению с ССССИ. Высокие значения этих предикторов также оказывают положительное влияние, в то время как низкие значения оказывают отрицательное влияние на прогнозы. Однако разброс и плотность значений SHAP, как правило, меньше. Это говорит о том, что, хотя NDVI и отдельные спектральные диапазоны влияют на предсказания модели, их влияние не такое сильное и последовательное, как у ССССИ.

Разброс значений SHAP для каждого предиктора указывает на вариабельность, которую они вносят в прогнозы модели. Широкий разброс значений SHAP означает, что предиктор вносит свой вклад с высокой степенью вариабельности, существенно влияя на прогноз, как в положительную, так и в отрицательную сторону, в зависимости от значения признака. Для ССССИ широкое распространение значений SHAP подчеркивает их роль в обеспечении существенной изменчивости модели, что делает их критически важными для определения прогнозируемых результатов. Напротив, предикторы с более узким разбросом, такие как некоторые спектральные диапазоны, указывают на более умеренное и последовательное влияние на предсказания модели.

В целом, график пчелиный рой дает наглядное представление о распределении и влиянии значений SHAP между предикторами. Это помогает понять относительную важность и динамический характер вклада предикторов в модель. Это показывает, что, хотя в предсказания вносят свой вклад многочисленные предикторы, CCCI оказывает наиболее сильное влияние с отчетливым и последовательным эффектом, в то время как другие характеристики, такие как NDVI и спектральные диапазоны, оказывают менее выраженное, но все же значимое влияние на предсказания модели.

Анализ распределения значений SHAP с использованием скрипичных диаграмм

На рис. 2.10 представлено распределение влияния каждого из предикторов на выходные данные модели. Каждая, так называемая скрипка, показывает диапазон и концентрацию значений SHAP для конкретного предиктора. Скрипичная диаграмма позволяет получить представление о величине и вариабельности влияния предикторов на предсказания модели. Ширина каждой скрипичной диаграммы в разных точках вдоль оси значений SHAP показывает плотность прогнозов с одинаковыми значениями SHAP. Таким образом, скрипичная диаграмма отображает вклад предикторов в производительность модели.

Кроме того, на рис. 2.10 показано, что CCCI имеет самое широкое распределение значений SHAP. Это говорит о том, что CCCI вносит наибольшую вариативность во влияние на выходные данные модели, при этом значения SHAP широко варьируются от отрицательных до положительных воздействий. Такая изменчивость подтверждает, что CCCI является важным фактором, влияющим на предсказания модели, где высокие значения характеристик могут значительно улучшить предсказания, в то время как низкие значения могут в равной степени уменьшить их. Широкое и разнообразное распределение подчеркивает, что CCCI играет решающую роль в формировании поведения модели, отражая положительный и отрицательный вклад в набор данных.

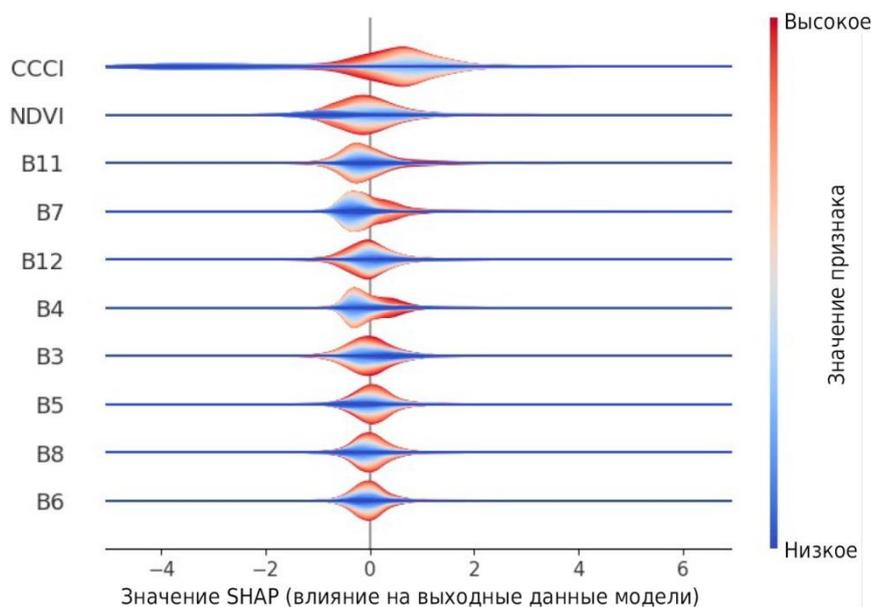


Рис. 2.10. График распределения значений SHAP для диапазонов Sentinel-2 и спектральных индексов на скрипичной диаграмме

Для диапазонов B11 (SWIR 1), B7 (VRE 3) и B12 (SWIR 2) графики скрипок демонстрируют умеренный разброс в распределении значений SHAP. Это указывает на то, что, хотя эти диапазоны заметно влияют на предсказания модели, их влияние менее доминирующее или изменчивое, чем у CCCI. Более узкое распределение также предполагает умеренный вклад. Следовательно, эти диапазоны не влияют на результаты модели так сильно, как CCCI.

Напротив, такие характеристики, как диапазоны B6 (VRE 2) и B8 (NIR), демонстрируют гораздо более узкое распределение значений SHAP, что указывает на ограниченную роль в процессе прогнозирования модели. Узкая форма скрипок позволяет предположить, что эти характеристики вносят минимальный вклад в общие прогнозы, поскольку большинство их значений SHAP сгруппированы вокруг нуля. Такой ограниченный разброс означает изменения в этих характеристиках существенно не влияют на результаты моделирования.

В целом, скрипичная диаграмма помогает нам понять, какие характеристики важны и как они влияют на все прогнозы. Широкие диапазоны, например, как показано на примере CCCI, указывают на факторы, оказывающие более динамичное и влиятельное воздействие. Напротив, узкие диапазоны отражают факторы, роль которых более ограничена и согласованна. Такая интерпретация помогает уточнить выбор признаков, определяя предиктор, который вносит наиболее изменчивый и значительный вклад в выходные данные модели. Эта информация может быть использована для улучшения модели или дальнейшего анализа.

Анализ точечных диаграмм распределения значений SHAP

На рис. 2.11 показано как значения предикторов соотносятся с соответствующими значениями SHAP. Этот анализ позволяет получить представление о вкладе каждого предиктора в предсказания модели. Точечные диаграммы помогают визуализировать, оказывает ли тот или иной предиктор положительное или отрицательное влияние на выходные данные модели и как это влияние меняется при различных значениях предиктора.

Для диапазонов B3, B4, B5 и B8 значения SHAP в основном сосредоточены в диапазоне от -0,5 до 0,5, с небольшим разбросом, как в положительную, так и в отрицательную стороны. Это говорит о том, что предикторы оказывают относительно слабое влияние на выходные данные модели. Отсутствие четкой тенденции к повышению или понижению значений SHAP во всем диапазоне значений предиктора означает, что влияние этих диапазонов относительно стабильно и оказывает минимальное влияние на выполнение прогнозов модели в определенном направлении. Большие или меньшие значения коэффициента отражения в этих диапазонах не оказывают заметного влияния на предсказания модели, что подчеркивает их ограниченную роль.

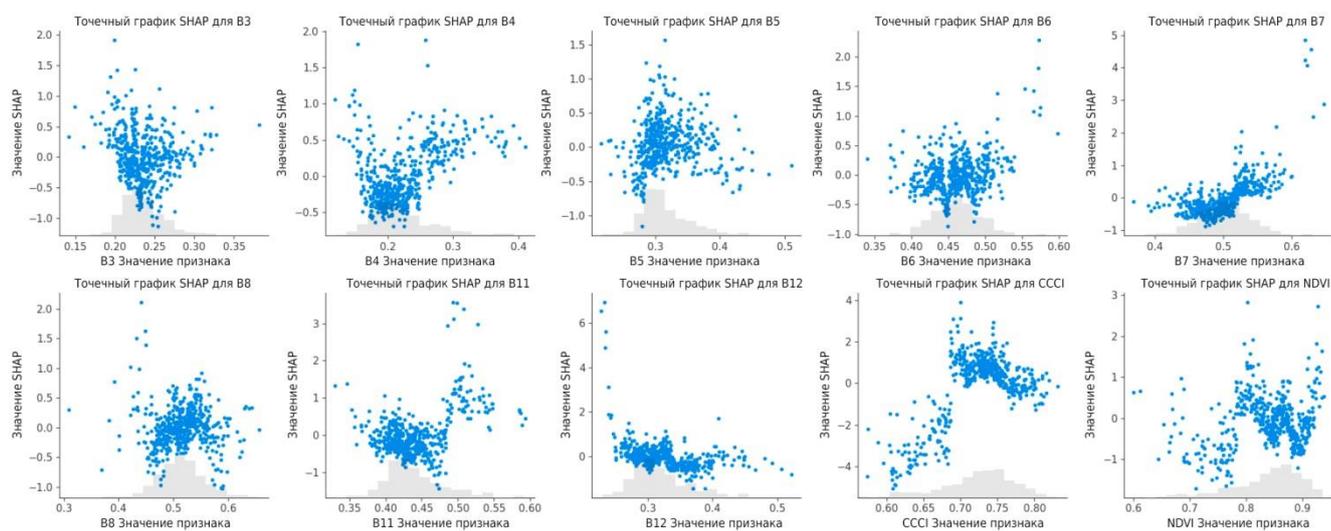


Рис. 2.11. Точечные графики зависимости значений SHAP от значений предикторов для диапазонов Sentinel-2 и спектральных индексов

Диапазоны B7 и B11 показывают отчетливую положительную корреляцию между значениями предиктора и SHAP. Это означает, что более высокая отражательная способность в этих полосах, как правило, оказывает более сильное положительное влияние на прогнозы модели. Диапазон B12 (SWIR 2) также демонстрирует положительную взаимосвязь между

коэффициентом отражения в спектре и значениями SHAP. Однако эта тенденция менее линейна, чем в B7 и B11, что подразумевает более сложное влияние.

Индекс содержания хлорофилла в древесном покрове (СССИ) имеет характерную закономерность с широким диапазоном значений SHAP. Высокие значения ССССИ неизменно положительно влияют на прогнозы модели, повышая значения SHAP. И наоборот, более низкие значения ССССИ оказывают негативное влияние. Такое четкое разделение между высокими и низкими значениями характеристик подчеркивает, что ССССИ играет важную роль в модели, существенно влияя на направление и значимость прогноза. Это наблюдение согласуется с более ранними анализами, в которых ССССИ был определен как основной фактор, влияющий на предсказания модели.

Нормализованный разностный индекс растительности (NDVI) также демонстрирует относительно сильную положительную взаимосвязь со значениями SHAP. Большие значения NDVI соответствуют более высоким положительным значениям SHAP, что указывает на существенное положительное влияние на результаты моделирования. Это отражает важность NDVI в модели. Хотя разброс значений SHAP для NDVI более компактен, чем для ССССИ, он по-прежнему существенно влияет на точность прогнозирования, подчеркивая его важность для учета характеристик растительности.

В целом, ССССИ оказывает наиболее сильное и последовательное влияние на прогнозы модели, при этом большие значения приводят к более высоким положительным значениям SHAP. Это говорит о том, что ССССИ является ключевым фактором прогнозирования в модели, существенно влияющим на выходные данные. NDVI, наряду с диапазонами B7 и B11, также демонстрирует явный положительный вклад. Более высокие значения этих характеристик положительно влияют на прогнозы модели. Напротив, связи B3 и B6 демонстрируют более слабые эффекты, причем их значения SHAP в основном сосредоточены вокруг нуля, что указывает на умеренное и менее направленное влияние на поведение модели.

2.4.2. Интерпретация локальных значений SHAP

Анализ локальных значений SHAP

Линейчатая диаграмма локальных значений SHAP (рис. 2.12) предоставляет подробную интерпретацию того, как каждый предиктор влияет на прогноз модели для конкретного наблюдения. Эта локальная интерпретация помогает нам понять, как значение каждого предиктора увеличивает или уменьшает выходные данные модели для отдельного прогноза. Анализ дает представление о результатах, полученных в одной точке данных.

Согласно рис. 2.12 диапазон B7 (VRE 3) вносит наибольший положительный вклад в прогноз модели, добавляя к результату приблизительно +1,02. Это указывает на то, что для данного конкретного наблюдения значение B7 значительно повышает прогноз. Сразу за B7 следует ССССИ, который также значительно увеличивает производительность модели, его вклад составляет +0,86. Значительный положительный вклад показателей B7 и ССССИ свидетельствует о том, что высокие значения этих характеристик, вероятно, повышают точность прогноза, что делает их доминирующими факторами при определении результатов для данного примера.

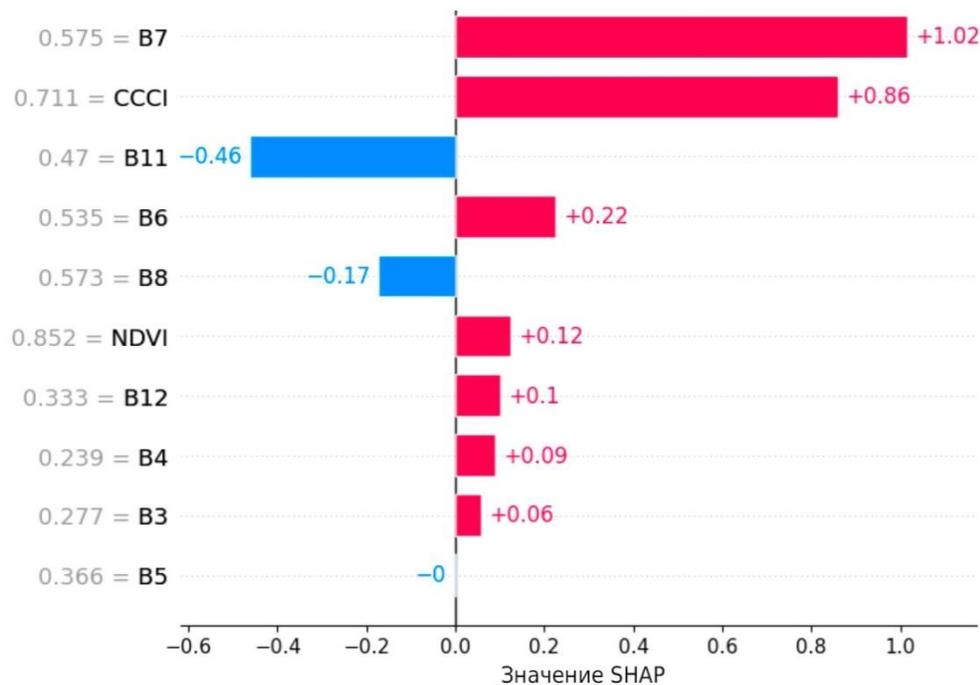


Рис. 2.12. Интерпретация вклада признаков в предсказание модели для одного наблюдения

Напротив, другие предикторы, такие как B11 и B8, оказывают негативное влияние на прогноз. В частности, B11 снижает выходные данные модели на $-0,46$, в то время как B8 оказывает меньшее негативное влияние на $-0,17$. Это говорит о том, что значения B11 и B8 для данного конкретного наблюдения противодействуют положительным вкладом других предикторов, тем самым снижая эффективность прогноза. Эти отрицательные вклады важны, поскольку они показывают, что не все предикторы поддерживают прогноз в одном и том же направлении. Скорее, они оказывают противоположное влияние, основанное на их индивидуальных особенностях.

Кроме того, другие предикторы, включая B6, NDVI, B12 и B3, оказывают положительное влияние в меньшей степени. Их значения SHAP значительно ниже по сравнению с B7 и CCCI, что свидетельствует о более умеренном влиянии на окончательный прогноз. Диапазон B6 добавляет $+0,22$, NDVI добавляет $+0,12$, а вклад других характеристик составляет менее $+0,1$, значит эти характеристики подтверждают прогноз. Таким образом, их влияние менее значительное по сравнению с доминирующими эффектами B7 и CCCI.

В целом, интерпретация этого локального графика SHAP показывает, что B7 и CCCI представляют собой основные факторы, влияющие на прогноз для данного конкретного наблюдения, что существенно повышает производительность модели. В то же время B11 и B8 служат противовесами, снижая выходное значение. Это локализованное представление вклада признаков дает полезную информацию о том, почему модель сделала тот или иной прогноз. Кроме того подчеркивает взаимосвязь между факторами, которые вносят положительный вклад, и факторами, которые противоречат прогнозу.

Построение каскадного графика локального SHAP

На рис. 2.13 показана подробная разбивка того, как модель пришла к окончательному прогнозу, равному $13,596$ для конкретного наблюдения. Анализ показывает совокупный вклад каждого прогнозирующего фактора относительно базового значения, которое является средним результатом модели, равным $11,762$. На каждом шаге каскадного графика видно, в какой степени определенный предиктор добавляется к базовому значению или вычитается из него. Это дает представление о процессе принятия решений в модели для данного конкретного случая.

В соответствии с каскадным графиком B7 (VRE3) вносит наибольший положительный вклад в прогноз, добавляя +1,02 к окончательному значению. Это указывает на то, что B7 является наиболее влиятельной характеристикой, повышающей прогноз, что подчеркивает его важность для данного наблюдения. CCCI является следующим по значимости предиктором, который вносит дополнительный вклад в прогноз на +0,86, усиливая его важную роль в увеличении выходных данных модели для этого наблюдения. Данные, полученные от B7 и CCCI, показывают, что более высокие значения этих предикторов сильно влияют на прогноз.

Напротив, B11 (SWIR 1) отрицательно влияет на прогноз, уменьшая значение на -0,46. Это указывает на то, что B11 нейтрализует некоторые положительные эффекты от других предикторов для данного конкретного случая, тем самым снижая производительность модели. Отрицательный вклад говорит о том, что условия, связанные с B11 для этого наблюдения, менее благоприятны, что фактически ухудшает прогноз.

Другие предикторы, такие как B6 (VRE 2), NDVI и B8 (NIR), вносят более скромный вклад в прогноз, положительный или отрицательный. Например, коэффициент B6 добавляет +0,22 к результатам модели, в то время как коэффициент NDVI добавляет +0,12. И наоборот, коэффициент B8 вносит отрицательный вклад, вычитая -0,17 из прогноза. Такие меньшие вклады отражают точную настройку прогноза. Соответственно, несмотря на то, что эти предикторы играют определенную роль, их влияние менее значительно, чем у B7 и CCCI.

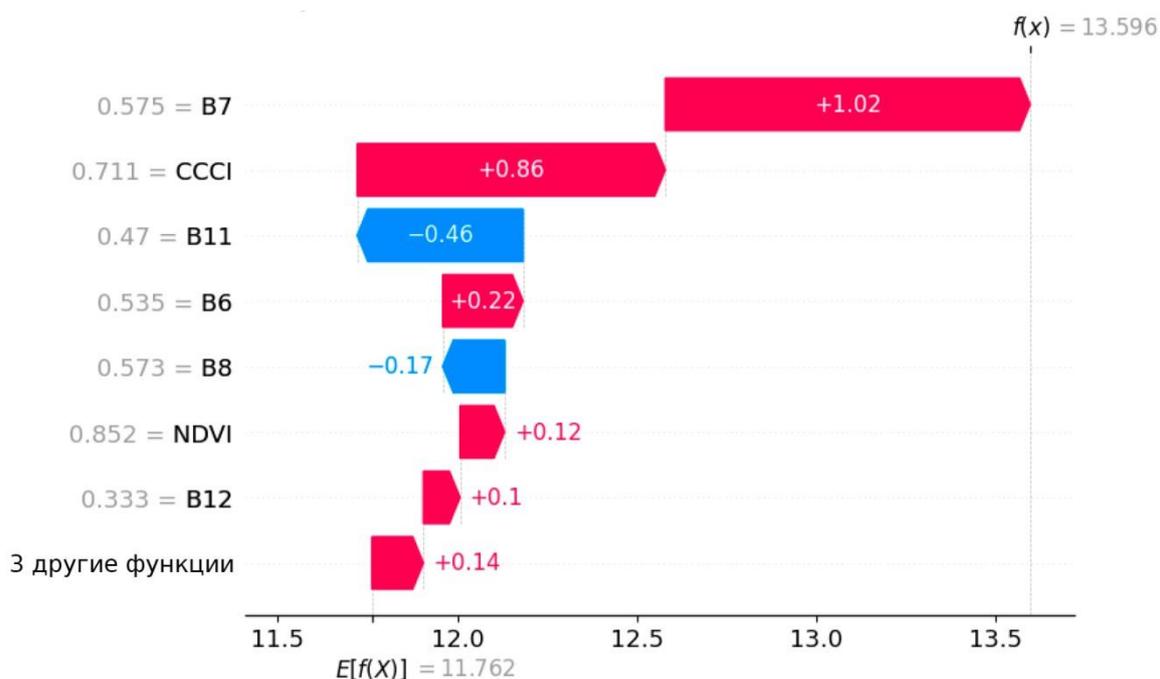


Рис. 2.13. Каскадный график SHAP, демонстрирующий вклад предиктора в конкретный прогноз

В конечном счете, итоговый прогноз, равный 13,596, достигается путем суммирования индивидуальных вкладов с базовым значением, равным 11,762. Каскадный график SHAP показывает, как каждый предиктор, положительно или отрицательно, влияет на выходные данные модели для данного конкретного наблюдения. Проведенный анализ позволяет интуитивно понять процесс принятия решений моделью для индивидуального прогнозирования.

2.5. Пространственный анализ вклада предикторов с использованием SHAP

Каждое подмножество карты SHAP (рис. 2.14) показывает локализованное влияние факторов CCCI, NDVI, B7 (VRE 3) и B8 (NIR) с цветовым градиентом от красного до синего.

Цветовая гамма отражает степень и направление влияния предиктора на прогноз модели. Красные области указывают на положительный вклад, в предположении, что значения этих предикторов способствуют более высоким оценкам высоты кроны в этих местах. И наоборот, синие области указывают на отрицательный вклад, означающий, что предикторы связаны с более низкими прогнозами высоты кроны.

Согласно рис. 2.14 CCCI и NDVI являются наиболее важными показателями для оценки высоты лесного покрова. На картах SHAP для этих показателей выделены более крупные красные области, что указывает на то, что высокое содержание хлорофилла и здоровая растительность положительно связаны с увеличением высоты лесного покрова. Эта закономерность подтверждает, что регионы с более высокими значениями CCCI и NDVI, скорее всего, будут иметь здоровую растительность, что в значительной степени влияет на прогноз высоты кроны деревьев в модели. Положительный вклад этих спектральных показателей имеет решающее значение для точного представления динамики вегетативного роста.

В то же время диапазоны B8 (NIR) и B7 (VRE 3) показывают меньшее количество областей с высоким влиянием, о чем свидетельствуют их ограниченные участки красного цвета на картах SHAP. Влияние этих диапазонов на прогноз высоты лесного покрова менее выражено по сравнению с CCCI и NDVI. Несмотря на то что они по-прежнему играют определенную роль, пространственный масштаб их влияния менее широк. Таким образом, эти диапазоны не всегда позволяют прогнозировать высоту лесного покрова на исследуемой территории. Это может свидетельствовать о том, что их значимость в большей степени зависит от контекста.

Пространственная визуализация, предоставляемая картами SHAP, имеет неоценимое значение для понимания локального вклада каждого предиктора в модель случайного леса (Random Forest). Карты SHAP предоставляют важную информацию заинтересованным сторонам, таким как органы управления лесами, выделяя наиболее важные переменные-предикторы для прогнозирования высоты лесного покрова. Другими словами, карты SHAP показывают, где влияние предикторов наиболее значительно. Более того, эти карты SHAP полезны для исследователей и разработчиков моделей, предоставляя критическую информацию о производительности модели, учитывая ее пространственный характер. Понимание того, как объекты влияют друг на друга в разных регионах, может помочь усовершенствовать обучение модели и повысить пространственную точность, что потенциально может привести к повышению предсказательной способности и обобщению. Хотя преимущества этих визуализаций значительны, стоит отметить, что создание карт SHAP требует больших вычислительных затрат. Этот конкретный анализ занял около трех часов, чтобы рассчитать карты SHAP для подмножества исследуемой территории. Таким образом, возникает необходимость оптимизировать вычисление значений пространственной формы, чтобы сделать этот ценный инструмент более доступным для более широкого применения без существенной вычислительной нагрузки.

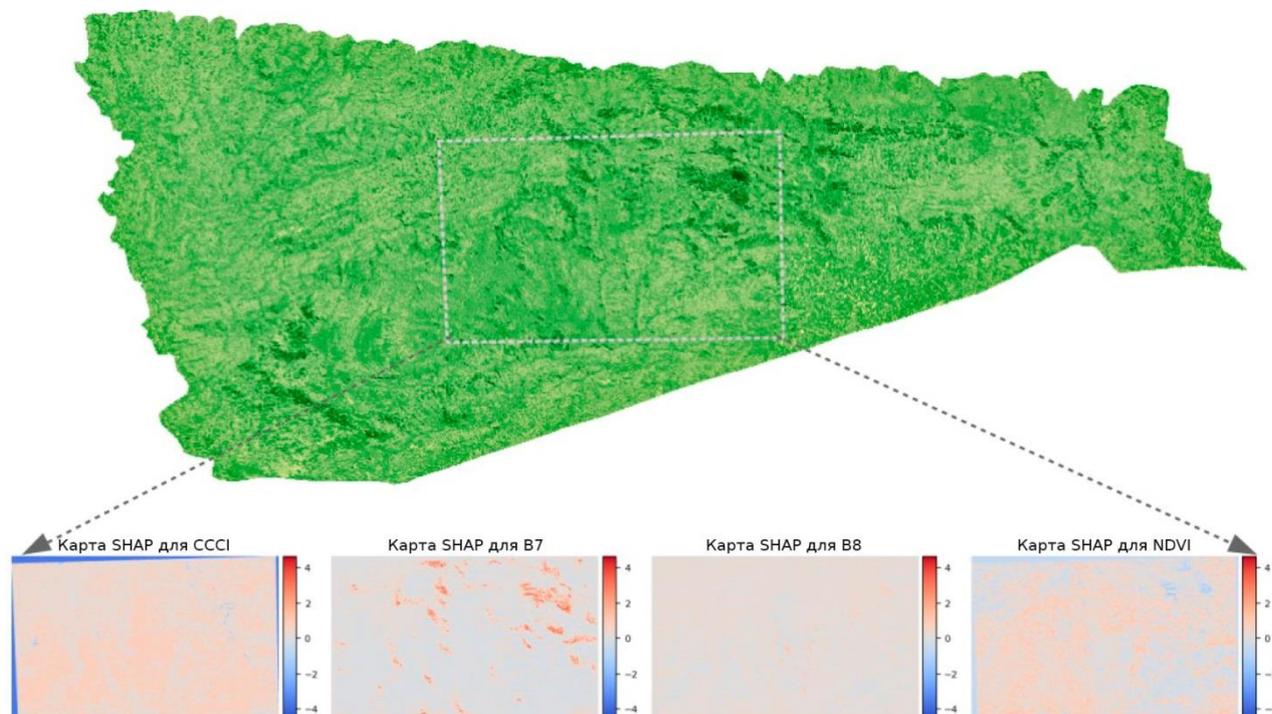


Рис. 2.14. Подмножество карт SHAP, показывающих вклад предикторов в прогнозирование высоты лесного покрова

2.6. Краткие итоги

В главе 2 рассмотрено практическое исследование, посвященное объяснимым методам машинного обучения для моделирования структуры лесов, с использованием модели случайного леса (Random Forest). Данные о высоте полога леса GEDI, восемь диапазонов Sentinel-2 и два спектральных индекса NDVI и CCCI. Эти спектральные показатели необходимы для оценки состояния и продуктивности растительности. Мы также провели предварительный анализ данных с использованием прямоугольных диаграмм и графиков плотности. Предварительный анализ данных с использованием прямоугольных диаграмм и графиков плотности выявил важные моменты, которые имеют решающее значение перед подготовкой модели машинного обучения (ML).

Мы также оценили эффективность регрессионной модели случайного леса (Random Forest Regression – RMSE), используя метод 10-кратной перекрестной проверки. Различия в показателях RMSE на разных итерациях указывают на необходимость дальнейших улучшений модели. В частности, требуется очистка данных, учитывая отклонения, присутствующие в обучающих данных. Предсказания модели относительно высоты кроны деревьев были сопоставлены с эталонными высотами кроны деревьев GEDI, что выявило слабую линейную зависимость и постоянное завышение. Это указывает на трудности, с которыми сталкивается модель при точном отражении всей изменчивости высоты лесного покрова, особенно для более высоких деревьев. В этой главе отмечена важность повышения точности модели для повышения надежности прогнозирования высоты леса в экологических целях.

Наконец, мы использовали значения SHAP, чтобы понять вклад различных предикторов в выходные данные модели. Был проведен как глобальный, так и локальный анализ значений SHAP, который позволил понять, какие предикторы в наибольшей степени повлияли на прогнозы модели. CCCI и NDVI стали ключевыми факторами, оказывающими значительное и устойчивое положительное влияние на прогнозы высоты кроны деревьев. Визуализации значений SHAP, включая линейные графики, графики в виде пчелиного роя, точечные графики, скрипичные графики и каскадные графики, выявили важнейшие особенности и их влияние в индивидуальном и глобальном контекстах. Кроме того, пространственные карты SHAP

предоставили ценную визуализацию того, как эти особенности влияют на различные регионы, предлагая заинтересованным сторонам более четкое понимание того, какие предикторы наиболее важны и где их влияние наиболее сильно. В конце главы обсуждалась вычислительная трудоемкость создания карт SHAP, что указывает на необходимость оптимизации, чтобы сделать этот инструмент более практичным для крупномасштабного пространственного анализа.

Глава 3. Практический пример 2: Объяснимое глубокое обучение для составления карт последствий наводнений

3.1. Введение

Наводнения остаются одними из самых разрушительных и широко распространенных стихийных бедствий во всем мире, приводя к значительным человеческим, экономическим и экологическим потерям [Bentivoglio et al., 2022]. Следовательно, картографирование последствий наводнений имеет решающее значение для эффективного управления стихийными бедствиями, городского планирования и стратегий смягчения последствий. Точные карты наводнений позволяют государственным органам и службам реагирования на чрезвычайные ситуации разрабатывать обоснованные планы действий, определять приоритетность районов повышенного риска и снижать долгосрочные последствия наводнений. Поскольку изменение климата продолжает увеличивать частоту и серьезность наводнений, потребность в точном составлении карт наводнений стала еще более насущной для защиты жизней, инфраструктуры и экосистем [Lee & Li, 2024].

За последние несколько десятилетий исследователи все чаще обращались к данным наблюдения Земли (Earth observation) для расширения возможностей картографирования последствий наводнений. Данные наблюдения Земли, в частности спутниковые снимки, предоставляют уникальную возможность фиксировать крупномасштабную пространственную динамику наводнений, что делает их ценным инструментом для анализа последствий наводнений, ресурсом для оценки риска наводнений. Однако традиционные подходы к составлению карт затопления в результате наводнений сталкиваются с рядом ограничений. Одной из основных проблем было использование изображений с низким и средним пространственным разрешением, на которых часто отсутствовали пространственные детали, необходимые для точного представления последствий наводнений для критически важных объектов инфраструктуры, таких как здания и дороги [Bentivoglio et al., 2022]. Кроме того, традиционные методы обработки изображений с высоким разрешением требовали больших вычислительных затрат и в значительной степени зависели от ручной интерпретации. Это сделало процесс трудоемким и отнимающим много времени, что привело к значительным задержкам в создании карт наводнений во время чрезвычайных ситуаций, когда своевременная информация имеет решающее значение [Sanderson et al., 2023]. Вычислительные требования к этим методам и временные ограничения также ограничивают их масштабируемость, что делает их менее эффективными для реагирования на крупномасштабные или быстро развивающиеся наводнения [Lin et al., 2023].

Недавние достижения в области глубокого обучения (DL), в частности разработка и применение сверточных нейронных сетей (CNNs), значительно изменили картографирование с использованием аэрофотоснимков или спутниковых снимков высокого разрешения. CNNs особенно хорошо подходят для обработки изображений с высоким разрешением, поскольку они превосходно распознают пространственные структуры, что делает их высокоэффективными для определения масштабов наводнений [Bentivoglio et al., 2022]. Модели глубокого обучения (DL) сокращают ручные усилия, необходимые для проектирования объектов. Они могут эффективно обрабатывать большие объемы спутниковых снимков, создавая точные карты наводнений практически в режиме реального времени. Кроме того, объединение нескольких источников данных, таких как радары с синтезированной апертурой (Synthetic Aperture Radar – SAR)

и оптические изображения, позволило моделям преодолеть проблемы с качеством данных, такие как облачный покров [Sanderson et al., 2023].

В дополнение к повышению точности и эффективности модели глубокого обучения (DL) обеспечили расширенную масштабируемость картографирования наводнений. Передовые архитектуры сверточных нейронных сетей (CNN), такие как U-Net, продемонстрировали свою способность обрабатывать большие массивы данных и создавать карты наводнений высокого разрешения в различных географических регионах [Lin et al., 2023]. Эти возможности имеют решающее значение для обеспечения быстрого реагирования на наводнения как на местном, так и на региональном уровнях. Таким образом, модели глубокого обучения (DL) являются незаменимым инструментом для управления рисками наводнений.

Несмотря на эти достижения, проблемы остаются. Одной из постоянных проблем является обобщение модели – обеспечение того, чтобы модель, подготовленная в одном регионе или для одного типа наводнений, могла эффективно применяться к различным регионам или сценариям наводнений. События, связанные с наводнениями, могут сильно различаться по своей природе под влиянием различных климатических, топографических и гидрологических условий. Такая изменчивость затрудняет разработку единой модели, которая бы согласованно работала во всех сценариях. Более того, учет неопределенности в прогнозах остается важнейшей областью исследований, особенно в связи с тем, что лицам, принимающим решения, необходимо четкое понимание надежности результатов моделирования для принятия обоснованных решений во время чрезвычайных ситуаций [Bentivoglio et al., 2022]. Кроме того, растет потребность в объяснимости моделей глубокого обучения (DL). Объяснимость имеет решающее значение для повышения доверия к моделям и прозрачности. Например, ученые и политики могут понять факторы, влияющие на результаты моделирования.

В главе мы рассмотрим эти пробелы, используя бесплатные данные из Kaggle (рис. 3.1), чтобы составить карту наводнений с использованием методов глубокого обучения (DL) и объяснимого ИИ (XAI). В частности, мы используем модель U-Net для автоматизированного проектирования объектов и составления карт. Кроме того, мы используем градиентно-взвешенное отображение активации классов (Grad-CAM) для визуализации областей входных изображений, наиболее влияющих на процесс принятия решений в модели. Grad-CAM обеспечивает важный шаг на пути к объяснимому DL, позволяя заинтересованным сторонам лучше интерпретировать и понимать предсказания модели. Это приведет к разработке более информированных и прозрачных стратегий борьбы со стихийными бедствиями, вызванными наводнениями, и смягчения их последствий.

Примечание переводчика. Kaggle – конкурсная платформа по исследованию данных, а также социальная сеть специалистов по обработке данных и машинному обучению. С 2017 года принадлежит корпорации Google. Сайт <https://www.kaggle.com/> организован как публичная веб-платформа, на которой пользователи и организации могут публиковать наборы данных, исследовать и создавать модели, взаимодействовать с другими специалистами по данным и машинному обучению, организовывать конкурсы по исследованию данных и участвовать в них.

Образец входного RGB-изображения



Образец маски



Рис. 3.1. Примерный набор данных о паводках. Затопленные участки выделены белым цветом, а незатопленные – черным

3.2. Модель U-Net

Модель U-Net, инновационная архитектура сверточной нейронной сети (CNN) в виде U-образного кодера-декодера, изначально была разработана для сегментации биомедицинских изображений [Ronneberger et al., 2015]. В этом исследовании модель U-Net была обучена с использованием набора данных Kaggle, тщательно настроив ключевые параметры и гиперпараметры для оптимизации производительности. Эти корректировки включали в себя точную настройку начальной скорости обучения, размера пакета и количества периодов обучения, а также выбор соответствующих элементов, таких как функция потерь, алгоритм оптимизации и показатели оценки. Методы увеличения объема данных были также применены для увеличения разнообразия обучающего набора и повышения надежности модели, что в конечном итоге привело к лучшему обобщению в задачах картографирования последствий наводнений.

На рис. 3.2 представлена информация о результатах обучения и валидации (проверки) модели U-Net за 70 эпох с использованием точности и потерь в качестве показателей для оценки ее эффективности. График точности модели иллюстрирует прогрессию точности обучения и валидации с течением времени. Первоначально точность обучения (синяя линия) начинается примерно с отметки 0,6 и постепенно увеличивается, достигая примерно 0,87 к заключительному этапу. Это постоянное повышение точности говорит о том, что модель эффективно учится классифицировать входные данные. Между тем, точность валидации (оранжевая линия) на ранних этапах демонстрирует некоторые колебания, что характерно для адаптации модели к различным наборам данных. Однако постепенно она стабилизируется, приближаясь к отметке 0,86. Точность валидации тесно связана с точностью обучения, и обе кривые сходятся к концу обучения. Эта сходимость указывает на то, что модель хорошо поддается обобщению без существенного переобучения и одинаково работает как с видимыми (обучающими), так и с невидимыми (проверяющими) данными.

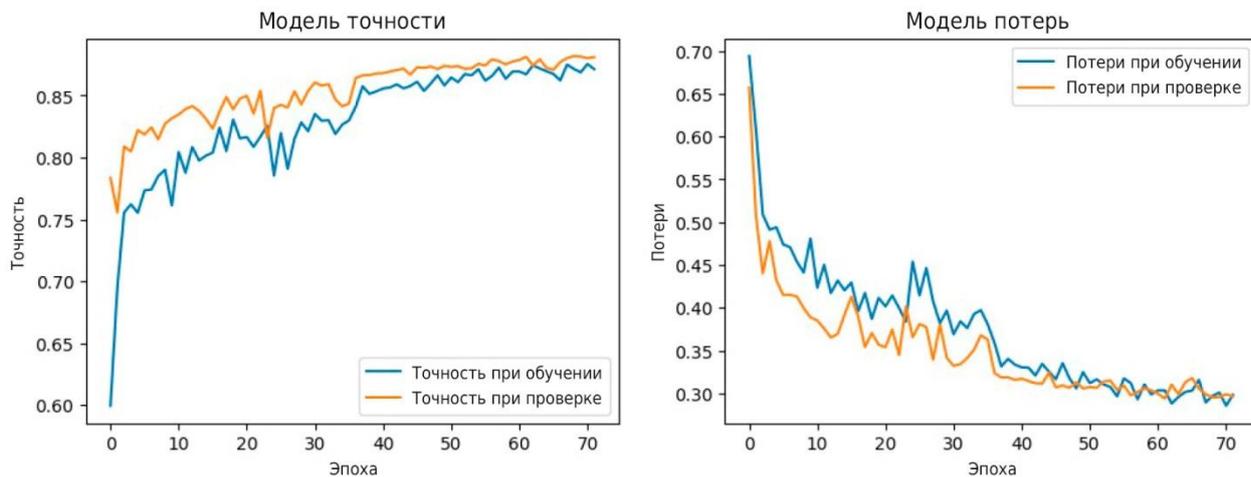


Рис. 3.2. Визуализация результатов модели U-Net

График потерь модели демонстрирует динамику потерь на протяжении всего процесса обучения. Потери при обучении (синяя линия) резко снижаются в начальные периоды, что отражает способность модели быстро извлекать уроки из данных обучения. По мере продолжения обучения потери снижаются постепенно, но последовательно, что указывает на устойчивое улучшение прогностических возможностей модели. Потери при проверке (оранжевая линия) следуют аналогичной траектории, существенно снижаясь в начале и оставаясь близкими к потерям при обучении на протяжении эпох. Сходимость результатов обучения и потерь при проверке достоверности, близких к аналогичным значениям, также свидетельствует о том, что модель сбалансирована и хорошо обобщается, успешно фиксируя лежащие в основе данных закономерности без чрезмерной адаптации к обучающему набору.

Модель U-Net демонстрирует высокую эффективность по обоим показателям. Сходимость кривых обучения и проверки точности и потерь без существенных расхождений свидетельствует об эффективном обучении и хорошем обобщении. Отсутствие какого-либо существенного разрыва между кривыми обучения и валидации подтверждает, что модель не является ни недостаточной, ни избыточной, а ее способность эффективно прогнозировать наводнения неуклонно повышается.

3.3 Карты паводковых зон

На рис. 3.3 показаны входное изображение, истинная маска и маска прогнозируемого наводнения. На входном изображении показана затопленная область, большая часть ландшафта которой покрыта водой. Истинная маска, которая служит в качестве базовой, правильно определяет затопленные области белым цветом, а незатопленные области черным. Эта маска служит ориентиром для оценки точности сегментации модели U-Net.

Прогнозируемая маска, сгенерированная с помощью модели, отражает общую структуру затопленных районов и достаточно хорошо соответствует истинной маске. Однако есть некоторые несоответствия, особенно в верхней части изображения, где модель переоценивает степень затопления, что приводит к появлению дополнительных белых областей, которые не были затоплены. Кроме того, некоторые небольшие затененные области, особенно в центральной и нижней частях изображения, пропущены или неправильно сегментированы моделью.

В целом, модель U-Net хорошо зарекомендовала себя при выявлении крупных зон затопления. Однако есть области, где сегментация менее точна, особенно в случае чрезмерного прогнозирования затопленных регионов и отсутствия мелких деталей. Кроме того, может потребоваться настройка модели для повышения точности прогнозов, уменьшения количества ложных срабатываний и улучшения определения небольших зон затопления.



Рис. 3.3. Входные данные модели U-Net, маска и прогнозируемое наводнение

3.4. Интерпретация Grad-CAM

На рис. 3.4 представлена серия изображений для визуализации и интерпретации результатов Grad-CAM, включая исходные изображения наводнений (левая колонка), тепловые карты Grad-CAM (средняя колонка) и наложения Grad-CAM (правая колонка). Визуализация с помощью Grad-CAM позволяет получить важное представление о том, на какие области входных изображений ориентировалась модель глубокого обучения (DL) при прогнозировании зон затопления. На этих тепловых картах выделены критические области, которые модель учитывала при принятии решений, что повышает прозрачность ее внутренней работы и позволяет понять логику, лежащую в основе ее прогнозов.

На тепловых картах Grad-CAM (средняя колонка) ярко-красные и желтые области обозначают области, которым модель уделяла значительное внимание при составлении своих прогнозов. Напротив, синие области указывают на области, имеющие минимальное значение или не имеющие никакого значения для процесса принятия решений. Например, в первом ряду (изображение 5) модель сильно выделяет затопленные улицы в центре и в правом нижнем углу, выделенные ярко-красными областями. Это говорит о том, что эти области сыграли решающую роль в способности модели обнаруживать наводнения на изображении. Аналогичным образом, во втором и третьем рядах (изображения 1022 и 3045) тепловые карты отображают области, наиболее пострадавшие от наводнения, такие как затопленные сооружения, заболоченная растительность и большие водные пространства. Интенсивность этих областей демонстрирует, что модель сосредоточена на наиболее подверженных воздействию участках.

Наложения изображения Grad-CAM (правая колонка) предоставляют объединенный вид исходных изображений и тепловых карт, что позволяет получить более полное представление о фокусе модели в кадре. В первом ряду (изображение 5) наложение указывает на то, что модель была сосредоточена в основном на затопленных улицах и территориях вблизи зданий, особенно вокруг зон затопления. Аналогичным образом, во втором ряду (изображение 1022) модель выделяет зоны затопления вблизи сооружений и растительности, что указывает на тесную связь между этими особенностями и прогнозом наводнений. Третий ряд (изображение 3045) показывает, что модель в значительной степени фокусировалась на больших затопленных территориях, о чем свидетельствуют ярко выраженные красные области, покрывающие обширные водоемы. Эти наложения помогают визуально оценить актуальность и точность фокусировки модели, помогая проверить, уделяет ли модель внимание правильным регионам, то есть районам, пострадавшим от наводнения.

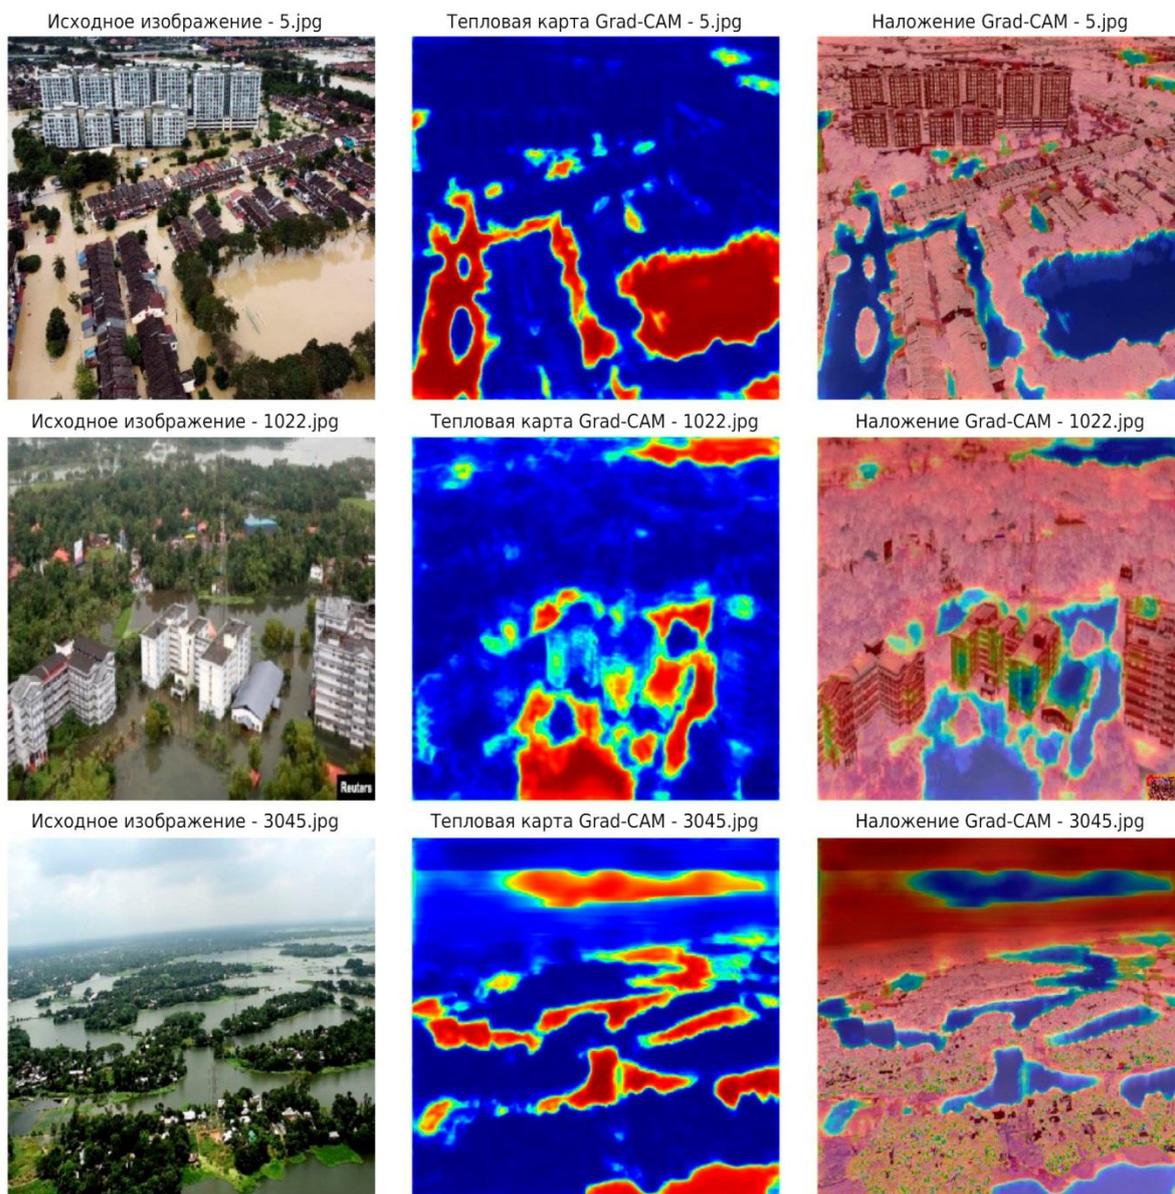


Рис. 3.4. Исходное изображение, тепловая карта и наложение Grad-CAM

В целом, результаты Grad-CAM показывают, что модель эффективно идентифицировала затопленные регионы, уделяя особое внимание ключевым областям, таким как водоемы и затопленные сооружения. Тепловые карты дают представление о решениях модели, показывая, какие части изображения в наибольшей степени повлияли на прогнозы модели. Эти визуализации играют важную роль в укреплении доверия к результатам модели, делая процесс глубокого обучения (DL) более прозрачным и понятным. Это особенно важно в приложениях с высокими ставками, таких как картографирование наводнений, где точные и надежные результаты необходимы для принятия решений.

3.5. Краткие итоги

В главе 3 рассмотрены возможные причины возникновения наводнений при составлении карт наводнений, подчеркивается полезность моделей U-Net и Grad-CAM. Составление карт наводнений имеет важное значение для обеспечения готовности к стихийным бедствиям, реагирования на них и смягчения их последствий, особенно в связи с тем, что последствия изменения климата увеличивают частоту и серьезность таких событий во всем мире. Несмотря на свою полезность, традиционные методы картографирования наводнений часто были ограничены низким разрешением, длительным временем обработки и трудоемкой ручной интерпретацией. Недавние достижения в области глубокого обучения (DL), в частности сверточные нейронные сети (CNNs), позволили составить более эффективное и точное

картографирование наводнений с более высоким разрешением, преодолев многие из этих традиционных проблем.

В данном исследовании модель U-Net использовалась для обнаружения и картографирования затопленных регионов. Модель U-Net достигла многообещающих результатов благодаря обучению модели на основе набора данных о наводнениях, полученного из Kaggle, и оптимизации гиперпараметров, таких как скорость обучения, размер пакета и периоды. Точность модели неуклонно повышалась в течение 70 периодов обучения, в конечном итоге достигнув почти оптимального значения, равного примерно 0,87, как для точности обучения, так и для точности валидации, с минимальными признаками переобучения. Кривые потерь при обучении и валидации также сходились, что указывает на эффективное обобщение невидимых данных. Несмотря на хорошую общую производительность, модель U-Net имела некоторые ограничения, особенно при выявлении небольших или более сложных зон затопления. Результаты сегментации показали, что модель переоценила масштабы затопления на определенных участках, но пропустила несколько небольших затопленных районов, выделив области, требующие дальнейшей доработки.

Для интерпретации прогнозов модели U-Net была использована система Grad-CAM, позволяющая визуально понять, какие области входных изображений повлияли на процесс принятия решений моделью. С помощью этого метода были созданы тепловые карты, показывающие области, на которые модель обращает особое внимание, такие как водоемы, подводная инфраструктура и другие затопленные районы. Ярко-красные и желтые области на тепловых картах указывают на регионы, где модель использовала наибольшую концентрацию при определении масштабов наводнений, что дает представление о логике принятия решений, лежащей в основе каждого прогноза. Наложение этих тепловых карт на исходные изображения наводнений позволило заинтересованным сторонам оценить актуальность фокуса модели. Это помогло подтвердить, что модель уделяла внимание правильным частям сцены, обеспечивая прозрачность процесса принятия решений.

В главе подчеркивается преобразующая роль объяснимых моделей глубокого обучения (DL) в составлении карт наводнений. Сочетание U-Net для точной сегментации и Grad-CAM для удобства интерпретации обеспечивает мощную основу для создания надежных и объяснимых карт наводнений. Такой подход может существенно помочь государственным служащим, специалистам по реагированию на чрезвычайные ситуации и ученым, обеспечивая точность и интерпретируемость прогнозов модели. Несмотря на то, что модель показала хорошие результаты, дальнейшие усовершенствования, такие как улучшенная настройка и увеличение объема дополнительных данных, могли бы помочь решить проблемы, связанные с завышением оценок и пропущенными деталями, особенно в сложных или локализованных сценариях наводнений. Использование Grad-CAM также демонстрирует важность прозрачности в глубоком обучении (DL), особенно в таких критически важных приложениях, как управление наводнениями.

Глава 4. Преимущества объяснимого ИИ: почему будущее за геопространственным моделированием

4.1. Введение

В заключительной части книги автор демонстрирует, как искусственный интеллект и геопространственные технологии могут взаимно усиливать их использование в анализе окружающей среды. Тематические исследования иллюстрируют возможности ГеоИИ для моделирования структуры лесов и составления карт паводков. В ней освещаются сильные стороны и ограничения передовых методов машинного (ML) и глубокого (DL) обучения. В нем также показано, как объяснимые методы, такие как аддитивные объяснения Шепли (SHAP), не зависящие от модели локальные интерпретируемые объяснения (LIME) и градиентно-взвешенное отображение активации классов (Grad-CAM), могут преодолеть разрыв между

сложными предсказаниями моделей и их объяснимостью. Эти методы объяснимого ИИ (ХАИ) позволяют заинтересованным сторонам увидеть предсказания моделей и факторы, влияющие на результат моделирования.

В таких важных областях, как управление окружающей средой, городское планирование и реагирование на стихийные бедствия, где решения, основанные на ИИ, могут иметь далеко идущие последствия, прозрачность является ключом к укреплению доверия и обеспечению принятия этичных, обоснованных решений. Такая прозрачность особенно важна, поскольку эти приложения напрямую влияют на природные ресурсы, сообщества и экосистемы. Объяснимый ГеоИИ может снизить риски, связанные с моделями «черного ящика». Кроме того, он делает решения в области искусственного интеллекта более понятными для неспециалистов, включая политиков, лидеров сообществ и другие заинтересованные стороны.

Эта перспективная книга знакомит с использованием искусственного интеллекта для геопространственного моделирования. Она также предлагает путь к более ответственному и прозрачному применению ГеоИИ в управлении природными ресурсами Земли и реагировании на проблемы окружающей среды. Книга также стимулирует интеграцию объяснимого ИИ (ХАИ) в качестве стандартной практики в рабочие процессы ГеоИИ. Это позволяет пользователям применять передовые модели ГеоИИ таким образом, чтобы поддерживать принципы прозрачности и подотчетности.

4.2. Преимущества и ограничения объяснимого ГеоИИ для моделирования высоты полога леса

Методы объяснимого ИИ (ХАИ) имеют решающее значение для выяснения того, какие спектральные диапазоны или индексы (NDVI и CCCI) определяют прогноз высоты полога леса. Предоставляя прозрачную информацию о том, как эти характеристики влияют на результаты моделирования, объяснимый ИИ (ХАИ) гарантирует, что модели не будут функционировать как простые «черные ящики». Вместо этого они дают значимое и информативное понимание моделей. Такая прозрачность делает прогнозы надежными и применимыми к действиям для заинтересованных сторон. Например, при управлении лесами необходимы надежные данные для планирования природоохранных мероприятий и стратегий управления, которые способствуют связыванию углерода.

Объяснимость также позволяет глубже понять, почему в определенных районах прогнозируется высокая или низкая высота крон деревьев. Например, ученые или исследователи могут использовать эти данные для улучшения обучающих данных или структуры модели. Объяснимый ИИ (ХАИ) может повысить применимость моделей случайного леса (Random Forest) в более крупных масштабах, выявляя факторы, влияющие на прогнозирование высоты лесного покрова. Такая масштабируемость позволяет более широко использовать источники данных, такие как спутниковые снимки Sentinel-2, что позволяет моделировать высоту лесного покрова на региональном или даже глобальном уровнях.

Однако, хотя значения SHAP и другие методы атрибуции объектов превосходно определяют важность отдельных предикторов, они часто не учитывают пространственный контекст – важнейший компонент в геопространственных приложениях. Взаимосвязи между прогностическими переменными часто зависят от пространства, а это означает, что предикторы могут оказывать неодинаковое влияние в разных местах. Чтобы устранить этот недостаток, в книге представлена концепция карт SHAP, которые обеспечивают пространственное представление вкладов предикторов. Благодаря интеграции пространственного контекста, карты SHAP улучшают интерпретируемость вкладов предикторов. Это гарантирует, что заинтересованные стороны понимают значимость предикторов, а также то, где и почему эти предикторы имеют значение в географическом ландшафте.

4.3. Преимущества и ограничения объяснимого ГеоИИ для картографирования последствий наводнений

Градиентно-взвешенное отображение активации классов (Grad-CAM) значительно усовершенствовало методы глубокого обучения (DL), такие как U-Net, предоставив визуальные пояснения в виде тепловых карт. Эти тепловые карты выделяют области входного изображения, на которые модель опиралась при принятии решений, что может быть чрезвычайно полезно для определения того, правильно ли модель определила затопленные районы и сфокусировалась ли она на соответствующих частях спутникового изображения. Такая информация необходима для проверки того, что модель дает точные и надежные прогнозы, особенно в таких важных приложениях, как картографирование последствий наводнений. При правильной настройке модели U-Net часто обеспечивают высокую точность при решении задач сегментации наводнений, позволяя различать затопленные и незатопленные участки с минимальными ошибками даже в реальных условиях.

Объяснимость также гарантирует, что модель хорошо подходит для различных областей, помогая выявлять закономерности наводнений в разных регионах. Это делает модели глубокого обучения (DL), такие как U-Net, особенно полезными для крупномасштабной борьбы со стихийными бедствиями, где модели должны адаптироваться к различным ландшафтам, сохраняя при этом надежность. Использование методов объяснимого ИИ (XAI) обеспечивает уровень надежности для служб экстренного реагирования и агентств по борьбе со стихийными бедствиями. Это служит также механизмом проверки, демонстрирующим, что модель ориентирована на реальные явления наводнения.

Однако, несмотря на возможности моделей U-Net, методы объяснения иногда могут выявлять проблемы, такие как завышенный прогноз затопленных районов в определенных регионах, что приводит к ложным тревогам. Такое завышение часто является следствием переобучения, особенно когда модели обучаются на ограниченных данных или не в состоянии отразить более мелкие детали изменчивости окружающей среды, такие как незначительные изменения высоты или локальной растительности. Эти ложные сигналы тревоги могут привести к неэффективному использованию ресурсов при ликвидации последствий наводнения и подорвать доверие к процессу принятия решений на основе искусственного интеллекта, особенно если модель ошибочно определяет районы как затопленные достаточно часто.

Тепловые карты градиентно-взвешенного отображения активации классов (Grad-CAM) предоставляют ценную визуальную информацию для специалистов в области глубокого обучения, но их интерпретация может быть сложной для неспециалистов. Заинтересованные стороны, которым не хватает обширных знаний в области геопространственного анализа или искусственного интеллекта, могут с трудом понять, что эти тепловые карты говорят о производительности или надежности моделей. Эта сложность представляет собой существенное ограничение в практических приложениях, где объяснимый ИИ (XAI) в идеале должен предоставлять информацию, доступную широкому кругу пользователей и пригодную для принятия мер. Чтобы максимально использовать объяснимый ГеоИИ, крайне важно разработать более простые и интуитивно понятные способы представления этих наглядных объяснений заинтересованным сторонам. Это упрощение гарантирует, что лица, принимающие решения, не обладающие специальными техническими знаниями, смогут понять и использовать важные идеи.

4.4. Будущая работа

В будущем ГеоИИ будет более органично интегрирован с методами обеспечения объяснимости. Это позволит разрабатывать усовершенствованные и прозрачные геопространственные модели, которые будут одновременно эффективными и объяснимыми. Некоторые аспекты выделяются в качестве перспективных областей для будущих исследований и практического применения.

В первую очередь интеграция методов объяснимого ИИ (ХАИ) с основными географическими принципами, такими как пространственная автокорреляция и пространственная неоднородность, может обеспечить понимание эффективности модели ГеоИИ. Включение таких географических принципов в методы обеспечения объяснимости также повысит объяснимость моделей ГеоИИ. Кроме того, это также позволит контекстуализировать ХАИ в пространственной структуре, предлагая более глубокое и содержательное понимание того, как пространственные взаимосвязи влияют на результаты моделирования.

Другим важным направлением будущих исследований является оптимизация эффективности существующих методов анализа геопространственных данных. Например, создание пространственных SHAP карт, используемых в этой книге, требует больших вычислительных затрат и часто занимает слишком много времени для крупномасштабных приложений. Поэтому необходима разработка более эффективных алгоритмов для вычисления значений пространственной SHAP формы. Более быстрые и выполнимые с точки зрения вычислений методы будут иметь решающее значение для расширения масштабов усилий по обеспечению наглядности, особенно для региональных или глобальных приложений с высоким разрешением данных.

Будущие направления исследований также должны быть направлены на разработку моделей, которые могут быть интерпретированы по своей сути. Вместо простого применения методов обеспечения объяснимости в качестве постфактум-решения создание интерпретируемых моделей по замыслу будет способствовать большей прозрачности. Более того, улучшение пространственных обобщений остается важнейшей исследовательской задачей, в частности, обеспечение воспроизводимости моделей ГеоИИ в различных географических контекстах. Расширенное пространственное обобщение позволило бы моделям, разработанным в одном регионе, эффективно применяться в других, обеспечивая более широкую применимость и уменьшая погрешности, которые могут возникнуть из-за региональных особенностей.

Еще одной перспективной областью, вызывающей интерес, становится рост социальной ответственности моделей ГеоИИ. Поскольку эти модели все чаще используются в городском планировании, мониторинге окружающей среды и борьбе со стихийными бедствиями, они могут существенно влиять на государственную политику и распределение ресурсов. Поэтому обеспечение ответственного подхода к разработке и внедрению моделей ГеоИИ имеет первостепенное значение. Это предполагает повышение их технической надежности и внедрение принципов честности, равноправия и инклюзивности в процесс моделирования, чтобы свести к минимуму непреднамеренные последствия и искажения [Li et al., 2024].

Взаимосвязь различных научных областей, таких как география, информатика, исследование окружающей среды и социальные науки, имеет важное значение для достижения этих целей. Непосредственное внедрение пространственного мышления в модели искусственного интеллекта обеспечит дальнейшее развитие ГеоИИ таким образом, чтобы оно оказывало долгосрочное научное и общественное воздействие. Уделяя приоритетное внимание междисциплинарным исследованиям, мы можем разрабатывать модели ГеоИИ, которые не только технически совершенные, но и соответствуют человеческим и природоохранным ценностям, что делает их более социально ответственными и эффективными.

4.5. Следующие шаги: как раскрыть весь потенциал объяснимого ГеоИИ

ГеоИИ революционизирует картографирование и моделирование окружающей среды, но остаются значительные препятствия. Как показано в книге, такие проблемы, как качество данных, точность моделей и их переобучение, по-прежнему актуальны. На примере

моделирования структуры леса стало ясно, что для достижения высокой точности требуется тщательная очистка данных, настройка модели и более глубокое понимание факторов, влияющих на прогнозы. Модели глубокого обучения также подвержены таким ловушкам, как переобучение – проблемам, которые требуют глубокого понимания того, как функционируют модели и как предикторные переменные влияют на их результаты. Именно здесь объяснимый ИИ (ХАИ) вступает в дело, устраняя разрыв между сложными моделями поведения и значимыми идеями, которые можно применить на практике. Однако на этом путь не заканчивается – предстоит еще многое раскрыть, понять и усовершенствовать.

Готовы ли вы сделать следующий шаг и по-настоящему овладеть объяснимым ГеоИИ? Я рад объявить о выходе моей электронной книги «Unlocking the Black Box: A Practical Guide to Explainable GeoAI for Environmental Modeling» (Разблокировка черного ящика: практическое руководство по объяснимому ГеоИИ для моделирования окружающей среды). Это всеобъемлющее руководство поможет вам не только освоить основы, но и научиться уверенно применять доступные методы ГеоИИ. Независимо от того, начинаете ли вы работать или стремитесь повысить свой профессиональный уровень, эта книга создана для того, чтобы помочь вам преодолеть разрыв между пониманием теории и достижением практического мастерства. Вы найдете подробные учебные пособия, практические упражнения и готовый к использованию код, которые помогут вам решать реальные задачи в области моделирования структуры лесов, оценки риска наводнений и других приложениях для геопространственного машинного обучения.

Будущее ГеоИИ принадлежит тем, кто не только готов его использовать, но и может объяснить, доверять и совершенствовать. Не оставайтесь в стороне, поскольку эта область развивается с головокружительной скоростью. Представьте, что вы понимаете прогнозы вашей модели, обосновываете свои результаты перед заинтересованными сторонами и получаете преимущество в ответственном и эффективном использовании ГеоИИ для решения задач анализа окружающей среды.

Это ваш шанс раскрыть истинный потенциал объяснимого геопространственного искусственного интеллекта (ГеоИИ) – понять ваши модели и освоить их, повышая точность, надежность и доверие к каждому результату. Оформите предварительный заказ прямо сейчас и получите эксклюзивную скидку для ранних покупателей. Зарегистрируйтесь или напишите мне сегодня!

Совершенствуйте свои навыки. Расширяйте свое влияние. Воспользуйтесь возможностями поддающегося объяснению геопространственного искусственного интеллекта (ГеоИИ).

Литература

Bentivoglio, R., Isufi, E., Jonkman, S. N., & Taormina, R. (2022). Deep learning methods for flood mapping: A review of existing applications and future research directions. *Hydrology and Earth System Sciences*, 26(8), 4345–4378. <https://doi.org/10.5194/hess-26-4345-2022>

Dubayah, R., Blair, J.B., Goetz, S., Fatoyinbo, L., Hansen, M., Healey, S., Hofton, M., Hurtt, G., Kellner, J., Luthcke, S., et al. (2020). The global ecosystem dynamics investigation: High-resolution laser ranging of the Earth's forests and topography. *Science Remote Sensing*, 1, 100002.

Gao, S., Hu, Y., & Li, W. (Eds.). (2023). *Handbook of Geospatial Artificial Intelligence*. CRC Press. <https://doi.org/10.1201/9781003308423>

Georganos, S., Grippa, T., Niang Gadiaga, A., Linard, C., Lennert, M., Vanhuysse, S., Mboga, N., Wolff, E., & Kalogirou, S. (2021). Geographical random forests: A spatial extension of the random forest algorithm to address spatial heterogeneity in remote sensing and population modelling. *Geocarto International*, 36(2), 121–136. <https://doi.org/10.1080/10106049.2019.1688980>

- Goodchild, M. F. (2004). *GIScience, geography, form, and process*. *Annals of the Association of American Geographers*, 94(4), 709-714. <https://doi.org/10.1111/j.1467-8306.2004.00426.x>
- Hofton, M., & Blair, J. B. (2019). *Algorithm Theoretical Basis Document (ATBD) for GEDI Transmit and receive waveform processing for L1 and L2 products*.
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). *An assessment of support vector machines for land cover classification*. *International Journal of Remote Sensing*, 23(4), 725-749. <https://doi.org/10.1080/0143116011004032>
- Jakubik, J., Roy, S., Phillips, C. E., Fraccaro, P., Godwin, D., Zadrozny, B., Szwarcman, D., Gomes, C., Nyirjesy, G., Edwards, B., Kimura, D., Simumba, N., Chu, L., Mukkavilli, S. K., Lambhate, D., Das, K., Bangalore, R., Oliveira, D., Muszynski, M., Ankur, K., Ramasubramanian, M., Gurung, I., Khallaghi, S., Li, H. (S.), Cecil, M., Ahmadi, M., Kordi, F., Alemohammad, H., Maskey, M., Ganti, R., Weldemariam, K., & Ramachandran, R. (2023). *Foundation models for generalist geospatial artificial intelligence*. Preprint available on arXiv. <https://doi.org/10.48550/arXiv.2310.18660>
- Lee, H., & Li, W. (2024). *Improving interpretability of deep active learning for flood inundation mapping through class ambiguity indices using multi-spectral satellite imagery*. *Journal Name, Volume(Issue), Page Numbers*
- Li, W., Arundel, S. T., Gao, S., Goodchild, M. F., Hu, Y., Wang, S., & Zipf, A. (2024). *GeoAI for science and the science of GeoAI*. *Journal of Spatial Information Science*, 29, 1-17. <https://doi.org/10.5311/JOSIS.2024.29.349>
- Li, X., Wessels, K., Armston, J., Hancock, S., Mathieu, R., Main, R., et al. (2023). *First validation of GEDI canopy heights in African savannas*. *Remote Sensing of Environment*, 285, 113402. <https://doi.org/10.1016/j.rse.2022.11>
- Lin, J., Sreng, C., Oare, E., & Batarseh, F. A. (2023). *NeuralFlood: An AI-driven flood susceptibility index*. *Frontiers in Water*, 5, 1291305. <https://doi.org/10.3389/frwa.2023.1291305>
- Liu, P., & Biljecki, F. (2022). *A review of spatially-explicit GeoAI applications in urban geography*. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102936. <https://doi.org/10.1016/j.jag.2022.102936>
- Milenković, M., Reiche, J., Armston, J., Neuenschwander, A., De Keersmaecker, W., Herold, M., & Verbesselt, J. (2022). *Assessing Amazon rainforest regrowth with GEDI and ICESat - 2 data*. *Science of Remote Sensing*, 5, 100051. <https://doi.org/10.1016/j.srs.2022.100051>
- Pal, M., & Mather, P. M. (2005). *Support vector machines for classification in remote sensing*. *International Journal of Remote Sensing*, 26(5), 1007-1011.
- Pierdicca, R., & Paolanti, M. (2022). *GeoAI: A review of artificial intelligence approaches for the interpretation of complex geomatics data*. *Geosci. Instrum. Method. Data Syst.*, 11(195-218). <https://doi.org/10.5194/gi-11-195-2022>
- Potapov, P., Li, X., Hernandez-Serna, A., Tyukavina, A., Hansen, M. C., Kommareddy, A., Pickens, A., Turubanova, S., Tang, H., Silva, C. E., Armston, J., Dubayah, R., Blair, J. B., & Hofton, M. (2021). *Mapping global forest canopy height through integration of GEDI and Landsat data*. *Remote Sensing of Environment*, 253, 112165. <https://doi.org/10.1016/j.rse.2020.112165>
- Rodriguez-Galiano, V. F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P. M., & Jeganathan, C. (2012). *Random forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture*. *Remote Sensing of Environment*, 121, 93-107. <https://doi.org/10.1016/j.rse.2011.12.021>
- Sanderson, J., Mao, H., Abdullah, M. A. M., Al-Nima, R. R. O., & Woo, W. L. (2023). *Optimal fusion of multispectral optical and SAR images for flood inundation mapping through explainable deep learning*. *Information*, 14(660). <https://doi.org/10.3390/info14120660>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). *Grad-CAM: Visual explanations from deep networks via gradient-based localization*. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 618-626)
- Shapley, L. S. (1953). *A value for n-person games*. In H. W. Kuhn & A. W. Tucker (Eds.), *Contributions to the Theory of Games II* (pp. 307-317). Princeton: Princeton University Press.

Sultan, R. I., Li, C., Zhu, H., Khanduri, P., Brocanelli, M., & Zhu, D. (2024). *GeoSAM: Fine-tuning SAM with sparse and dense visual prompting for automated segmentation of mobility infrastructure*. *arXiv preprint arXiv:2311.11319v2*

VoPham, T., Hart, J. E., Laden, F., & Chiang, Y. (2018). *Emerging trends in geospatial artificial intelligence (geoAI): Potential applications for environmental epidemiology*. *Environmental Health, 17(40)*. <https://doi.org/10.1186/s12940-018-0386-x>

Xie, Y., He, E., Jia, X., Bao, H., Zhou, X., Ghosh, R., & Ravirathinam, P. (2021). *A statistically-guided deep network transformation and moderation framework for data with spatial heterogeneity*. In *2021 IEEE International Conference on Data Mining (ICDM)* (pp. 767-776). *IEEE*. <https://doi.org/10.1109/ICDM50108.2021.00088>

Yang, H. L., Yuan, J., Lunga, D., Laverdiere, M., Rose, A., & Bhaduri, B. (2018). *Building extraction at scale using convolutional neural network: Mapping of the United States*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11(8)*, 2600-2614. <https://doi.org/10.1109/JSTARS.2018.2835370>

Приложение

Несколько ценных ресурсов и веб-сайтов, которые могут помочь глубже понять объяснимый ГеоИИ и объяснимый ИИ (ХАИ) в целом.

А. Общие ресурсы объяснимого ИИ (ХАИ)

1. SHAP (SHapley Additive exPlanations)

SHAP is one of the most widely used tools for explaining machine learning models. It provides both global and local interpretability for model predictions.

Website: <https://shap.readthedocs.io/en/latest/>

2. LIME (Local Interpretable Model-agnostic Explanations)

LIME is a popular tool for understanding individual predictions made by any machine learning model.

Website: <https://github.com/marcotcr/lime>

3. Google's Explainable AI (XAI) Tools

Google provides Vertex explainable AI tools that can be used to interpret and explain ML models.

Website: <https://cloud.google.com/vertex-ai/docs/explainable-ai/overview>

Б. ГеоИИ и ресурсы геопространственного моделирования

1. Prithvi - NASA & IBM Geospatial Foundation Model

Prithvi is a geospatial foundation model developed by NASA and IBM. It leverages Harmonized Landsat and Sentinel-2 (HLS) imagery and uses self-supervised learning for large-scale image analysis. Prithvi is particularly useful for applications like flood mapping, crop mapping, and wildfire prediction, and is designed to handle Earth observation datasets.

Website: <https://huggingface.co/ibm-nasa-geospatial/Prithvi-100M>

2. GeoSAM (Segment Anything Model for Geospatial Data)

GeoSAM is an advanced adaptation of the Segment Anything Model (SAM) developed for segmentation of satellite and aerial imagery. It uses sparse and dense prompts to automate segmentation tasks, significantly improving upon traditional CNN-based models for geospatial image analysis.

Website: <https://samgeo.gishub.org/>

3. Google Earth Engine

Google Earth Engine is one of the most widely used platforms for analyzing geospatial datasets. It supports large-scale geospatial data processing and includes tutorials for integrating machine learning models.

Website: <https://earthengine.google.com/>

В. Исследовательские и образовательные ресурсы ГеоИИ и объяснимого ИИ (XAI)

1. Explainable AI for Earth Observation (XAI4EO)

A platform that hosts research and tools related to explainable AI in Earth observation.

Website: <https://www.lancaster.ac.uk/scc/research/ai4eo/>

2. The Alan Turing Institute - Explainable AI Research

The Turing Institute offers insights and research publications on XAI, focusing on applications that include geospatial and environmental data.

Website: <https://www.turing.ac.uk/research/research-projects/project-explain>

Г. Библиотеки с открытым исходным кодом для ГеоИИ и объяснимого ИИ (XAI)

1. GeoPandas

A Python library for working with geospatial data, commonly used in conjunction with machine learning models for GeoAI applications.

Website: <https://geopandas.org/en/stable/>

2. PyTorch Geometric (PyG)

A library designed for graph-based deep learning, often used to analyze spatial data.

Website: <https://pytorch-geometric.readthedocs.io/en/latest/>

3. TensorFlow with Keras

TensorFlow's Keras API is frequently used for building and training deep learning models on geospatial data. You can apply XAI techniques like Grad-CAM directly in TensorFlow.

Website: <https://www.tensorflow.org/>

4. GeoShapley

A game theory approach to measuring spatial effects from machine learning models. GeoShapley is built on Shapley value and Kernel SHAP estimator.

Website: <https://github.com/Ziqi-Li/geoshapley>

Д. Учебные пособия и платформы для обучения

1. GeoAI tutorials at Ai.Geolabs

Ai.Geolabs offers many free courses on GeoAI applications.

Website: <https://aigeolabs.com/courses/>

2. Google AI Education - Explainability

Google's dedicated portal for learning AI, which includes explainability tutorials and resources.

Website: <https://explainability.withgoogle.com/>

Об авторе

Каридж Камюсоко (Courage Kamusoko, Machida, Tokyo, Japan) – независимый консультант по геопространственным вопросам: моделирование изменений в землепользовании и растительном покрове, а также разработка и внедрение систем управления геопространственными базами данных. Основные исследования Кариджа Камюсоко включают анализ изображений, полученных с помощью дистанционного зондирования, моделирование землепользования и растительного покрова, моделирование наземной биомассы, машинное и глубокое обучение. В дополнение к геопространственным исследованиям и консультированию,

он занимается практическим машинным обучением для анализа и моделирования геопространственных данных.

Публикации

1. *Kamusoko, C. (In press). Explainable Machine Learning for Geospatial Data Analysis: A Data-Centric Approach. Taylor and Francis.*

2. *Kamusoko, C. (2021). Optical and SAR Remote Sensing of Urban Areas: A Practical Guide. Springer.*

3. *Kamusoko, C. (2019). Remote Sensing Image Classification in R. Springer.*

4. *Kamusoko, C. (2021). Data-centric Explainable Machine Learning for Land Cover Classification: A Practical Guide in R. Self-published (<https://aigeolabs.com/books/>).*

5. *Kamusoko, C. (2021). Explainable Machine Learning for Land Cover Classification: An Introductory Guide. Self-published (<https://aigeolabs.com/books/>).*

6. *Murayama, Y., Kamusoko, C., Yamashita, A., Estoque, R.C. eds. (2017). Urban Development in Asia and Africa: Geospatial Analysis of Metropolises. Dordrecht: Springer, 424p.*

7. *Kamusoko, C., Mundia, C. N. and Murayama, Y. eds. (2011). Recent Advances in Remote Sensing and GIS in Sub-Sahara Africa. New York: Nova Publishers, 211p.*

Внесите свой вклад в книгу!!!

Спасибо, что прочитали мою книгу «Представление ГеоИИ. Тематические исследования в области объяснимого ГеоИИ для моделирования окружающей среды». Книга находится в стадии постоянной доработки. Я улучшу текст и добавлю новые главы. Если вы обнаружите в книге ошибку или что в ней чего-то не хватает, пожалуйста, напишите мне по адресу cou.kamusoko@aigeolabs.com.

Научное издание

Каридж Камюсоко

**Представление ГеоИИ.
Тематические исследования
в области объяснимого ГеоИИ
для моделирования окружающей среды**

Перевод с английского Г. Г. Побединского

Редактор Г. А. Нилова

Межрегиональная общественная организация «Российское общество геодезии,
картографии и землеустройства»

109316, г. Москва, Волгоградский проспект, д. 45, с.1, оф. 631.

<http://rosgeokart.ru/>, info@rosgeokart.ru

Подписано к публикации 24.03.2025. Электронное издание.

Доступ: <https://rosgeokart.ru/publications>