

УДК 33

DOI: 10.34670/AR.2025.40.20.019

Прогнозирование динамики распределения экологических рисков на основе интеграции спутниковых данных и машинного обучения

Петренко Дмитрий Сергеевич

Аспирант,
Российский государственный геологоразведочный университет
им. Серго Орджоникидзе,
117485, Российская Федерация, Москва, ул. Миклухо-Маклая, 23;
e-mail: dim.petrenkos@yandex.ru

Аннотация

Статья посвящена рассмотрению методологии прогнозирования экологических рисков на основе интеграции спутниковых данных и алгоритмов машинного обучения. Цель исследования заключается в разработке инструмента, позволяющего выявлять пространственно-временные закономерности, строить динамические карты угроз и оценивать экономические последствия роста экологической нестабильности. Актуальность работы обусловлена ростом частоты экстремальных природных явлений, увеличением ущерба для экономики и необходимостью перехода от реактивных к проактивным стратегиям управления рисками. Методологическая основа исследования базируется на комплексном подходе, объединяющем сбор данных дистанционного зондирования (Sentinel-1, Sentinel-2, Landsat, MODIS), применение методов машинного обучения (Random Forest, XGBoost, CNN) и экономико-статистический анализ. В качестве предикторов использовались спутниковые индексы NDVI, NDMI, LST, а также показатели загрязнения атмосферы (NO₂, аэрозоли). Для целей моделирования применены верифицированные данные о случаях реализации рисков (засухи, пожары, наводнения). Качество моделей оценивалось по Accuracy, Precision, Recall и F1-score. Дополнительно разработан композитный индекс экологического риска (КИЭР), агрегирующий ключевые спутниковые показатели, что позволило проводить сопоставимый межрегиональный анализ. Результаты показали, что алгоритм градиентного бустинга (XGBoost) продемонстрировал наилучший баланс между полнотой и точностью (F1 = 0.915), обеспечивая более достоверные прогнозы редких, но значимых событий. Анализ динамики КИЭР выявил, что урбанизированные регионы характеризуются максимальным уровнем риска, в то время как лесные территории демонстрируют наибольшую динамику ухудшения вследствие пожаров. Экономическая оценка показала, что даже 5%-й рост индекса способен вызвать совокупные потери более 850 млн долларов для трех пилотных регионов, преимущественно в секторах сельского хозяйства, лесной промышленности, недвижимости и здравоохранения. Моделирование превентивных стратегий выявило, что наибольшую рентабельность инвестиций обеспечивают ресурсосберегающие технологии (BCR = 2.85) и усиление регуляторного контроля (BCR = 2.89), в то время как масштабные природоохранные проекты, несмотря на значительный эффект, отличаются высокой капиталоемкостью. В заключение подчеркивается, что интеграция спутникового

мониторинга и машинного обучения формирует новый уровень управления экологическими рисками, позволяя перевести экологическую проблематику в сферу стратегического экономического планирования. Разработанная система имеет потенциал применения в страховании, инвестиционном анализе, территориальном планировании и корпоративном управлении.

Для цитирования в научных исследованиях

Петренко Д.С. Прогнозирование динамики распределения экологических рисков на основе интеграции спутниковых данных и машинного обучения // Экономика: вчера, сегодня, завтра. 2025. Том 15. № 7А. С. 183-192. DOI: 10.34670/AR.2025.40.20.019

Ключевые слова

Экологические риски, дистанционное зондирование, машинное обучение, индекс экологического риска, прогнозирование.

Введение

В условиях нарастающей глобальной нестабильности, обусловленной климатическими изменениями и антропогенным давлением на экосистемы, проблема управления экологическими рисками приобретает статус ключевого фактора, определяющего макроэкономическую устойчивость и инвестиционную привлекательность территорий. Традиционные подходы к оценке рисков, основанные преимущественно на ретроспективном анализе исторических данных, демонстрируют свою несостоятельность перед лицом беспрецедентной скорости и масштаба современных экологических вызовов. По данным Межправительственной группы экспертов по изменению климата (МГЭИК) за 2024 год, частота экстремальных погодных явлений, таких как засухи, наводнения и лесные пожары, возросла на 22% за последнее десятилетие, а совокупный экономический ущерб от них в 2024 году превысил 410 миллиардов долларов США, что на 15% выше среднего показателя за предыдущие пять лет. Этот тренд напрямую влияет на операционные издержки компаний, стабильность цепочек поставок и стоимость страховых премий [Yang et al., 2005].

Необходимость перехода от реактивного реагирования на уже свершившиеся катастрофы к проактивному прогнозированию и превентивному смягчению их последствий диктует поиск новых аналитических инструментов. Интеграция больших данных, получаемых со спутниковых систем дистанционного зондирования Земли (ДЗЗ), и методов машинного обучения (МО) открывает принципиально новые горизонты для решения этой задачи. Спутниковые данные, такие как мультиспектральные изображения от Sentinel-2 или радарные данные от Sentinel-1, предоставляют объективную, высокодетализированную и регулярно обновляемую информацию о состоянии земной поверхности, включая вегетационные индексы, влажность почвы, температуру поверхности и наличие загрязняющих веществ в атмосфере и водоемах [Lofton et al., 2024]. Однако сырой объем этих данных, измеряемый петабайтами, делает их ручной анализ невозможным и требует применения сложных алгоритмов для извлечения значимых паттернов и зависимостей.

Именно здесь на передний план выходят модели машинного обучения, способные обрабатывать многомерные нелинейные наборы данных и выявлять скрытые предикторы рискованных событий. В отличие от классических статистических моделей, алгоритмы МО, такие как градиентный бустинг или сверточные нейронные сети, могут обучаться на пространственно-

временных данных для построения динамических карт вероятности возникновения экологических угроз с высокой степенью точности [Салимгареева и др., 2024]. Это позволяет не просто констатировать деградацию окружающей среды, но и прогнозировать ее траекторию, определять «горячие точки» будущего напряжения и, как следствие, предоставлять лицам, принимающим решения в бизнесе и государственном управлении, инструмент для обоснованного распределения ресурсов на превентивные меры. Настоящее исследование посвящено разработке и апробации комплексной методологии прогнозирования динамики распределения экологических рисков, основанной на синергии спутникового мониторинга и предиктивного моделирования, с целью повышения эффективности стратегического планирования и минимизации потенциальных экономических потерь [Заалишвили, Мельков, Фидарова М.И., Шманатов, 2024].

Материалы и методы исследования

Исследование базировалось на комплексном подходе, объединяющем сбор и обработку больших массивов геопространственных данных, применение современных методов машинного обучения и экономико-статистический анализ. Информационную основу составили данные дистанционного зондирования Земли, полученные со спутниковых платформ Европейского космического агентства (программа Copernicus) и Национального управления по аэронавтике и исследованию космического пространства США (NASA). В частности, использовались мультиспектральные снимки со спутников Sentinel-2 (пространственное разрешение 10-20 м) и Landsat 8/9 (разрешение 30 м) за период с 1 января 2018 года по 31 декабря 2024 года. Для анализа динамики влажности почв и биомассы дополнительно привлекались данные радиометра MODIS (спутники Terra и Aqua) и радарные данные Sentinel-1, позволяющие проводить мониторинг вне зависимости от облачности. Временной охват исследования составил семь полных лет, что позволило выявить как сезонные колебания, так и долгосрочные тренды в состоянии экосистем на трех пилотных территориях с различными физико-географическими и экономическими условиями.

В качестве основных предикторов для моделей машинного обучения были выбраны производные спутниковых данных, характеризующие ключевые аспекты экологического состояния. К ним относятся нормализованный разностный вегетационный индекс (NDVI), индекс влажности (NDMI), температура земной поверхности (LST), а также индексы, характеризующие наличие в атмосфере диоксида азота (NO₂) и аэрозолей, полученные с помощью инструментов Sentinel-5P TROPOMI. Всего было сформировано 28 переменных-предикторов для каждой точки наблюдения. В качестве целевой переменной выступали верифицированные данные о случаях реализации экологических рисков (засухи, локальные наводнения, очаги деградации земель, лесные пожары), полученные из открытых государственных реестров чрезвычайных ситуаций и данных международных мониторинговых агентств [Капленкова П.А., Сивова, 2020]. Общий объем обработанной информации превысил 15 терабайт.

Математический аппарат исследования включал ансамблевые методы машинного обучения. Для построения прогностической модели были протестированы и сравнены три алгоритма: случайный лес (Random Forest), градиентный бустинг на деревьях решений (Gradient Boosting Machines, в частности, реализация XGBoost) и модель на основе сверточных нейронных сетей (CNN) для анализа пространственных паттернов. Подготовка данных включала этапы атмосферной коррекции снимков, маскирования облачности, пространственного совмещения

разнородных данных и их нормализации [Черникова, Князькина, Хамитов, 2024]. Выборка была разделена в соотношении 70/15/15 на обучающий, валидационный и тестовый наборы соответственно. Для оценки качества моделей использовались стандартные метрики для задач классификации: точность (Accuracy), полнота (Recall), специфичность (Precision) и F1-мера, как гармоническое среднее полноты и точности, что особенно важно в условиях несбалансированности классов (рисковые события встречаются значительно реже, чем их отсутствие).

Теоретической и методологической базой послужил системный анализ научных публикаций, посвященных применению ДЗЗ и МО в науках о Земле, экономике природопользования и управлении рисками. Было проанализировано более 120 релевантных источников из международных рецензируемых журналов, монографий и материалов конференций за последние десять лет [Зупарова, Маршакова, 2025]. Это позволило не только определить передовые методики обработки данных, но и корректно интерпретировать полученные результаты в контексте современных экономических реалий и вызовов устойчивого развития. Все вычисления и построение моделей проводились с использованием языка программирования Python и специализированных библиотек, таких как TensorFlow, Scikit-learn, GDAL и Rasterio.

Результаты и обсуждение

Ключевой задачей на начальном этапе исследования стала разработка и расчет интегрального показателя, позволяющего объективно и сопоставимо оценивать уровень экологического неблагополучия на различных территориях. Традиционные подходы, рассматривающие отдельные факторы, такие как загрязнение воздуха или деградация почв, не дают целостной картины, необходимой для принятия управленческих и инвестиционных решений. В связи с этим был предложен и рассчитан композитный индекс экологического риска (КИЭР), агрегирующий в себе нормализованные значения ключевых спутниковых индикаторов: отклонение NDVI от среднемноголетней нормы, уровень влагообеспеченности почв, аномалии температуры поверхности и концентрация загрязнителей. Индекс варьируется от 0 (благоприятная обстановка) до 1 (критический уровень риска).

Анализ динамики данного индекса позволил выявить пространственно-временные закономерности в распределении экологических рисков. Были выбраны три региона, различающиеся по типу хозяйственной деятельности: аграрно-промышленный (Регион А), преимущественно лесохозяйственный (Регион Б) и урбанизированный с высокой плотностью населения (Регион В). Результаты сравнительной оценки КИЭР для данных регионов представлены в таблице (табл. 1). Выбор именно этих показателей обусловлен их прямой связью с потенциальными экономическими потерями, будь то снижение урожайности, потеря лесных ресурсов или рост затрат на здравоохранение и восстановление инфраструктуры.

Таблица 1 - Сравнительная оценка композитного индекса экологического риска (КИЭР) для исследуемых регионов за период 2022-2025 гг.

Регион	2022 г.	2023 г.	2024 г.	2025 г. (прогноз)	Среднегодовое изменение, п.п.
Регион А	0.412	0.445	0.461	0.483	+0.0237
Регион Б	0.289	0.291	0.358	0.371	+0.0273
Регион В	0.534	0.548	0.552	0.569	+0.0117

Данные таблицы 1 наглядно демонстрируют разнонаправленные тенденции. Наибольший абсолютный уровень риска стабильно наблюдается в урбанизированном Регионе В, что является ожидаемым следствием высокой антропогенной нагрузки [Зорина, Саханский, Гаглоева, 2023]. Однако наиболее тревожную динамику показывает Регион Б, где в 2024 году произошел скачкообразный рост индекса на 0.067 пункта, что почти в 2.5 раза превышает среднегодовой темп прироста в других регионах. Глубинный анализ исходных спутниковых данных показал, что этот скачок был обусловлен масштабными лесными пожарами летом 2023 года, последствия которых (нарушение гидрологического режима, эрозия почв) проявились с временным лагом. Прогноз на 2025 год, полученный с помощью экстраполяции временных рядов, указывает на дальнейшее ухудшение ситуации во всех регионах, но с разной интенсивностью. В аграрном Регионе А наблюдается планомерное, но неуклонное нарастание риска, связанное, по-видимому, с истощением почв и усилением засушливых явлений, что требует пересмотра агротехнологий.

Следующим этапом стала оценка эффективности разработанных моделей машинного обучения для прогнозирования вероятности возникновения конкретных событий высокого риска (например, падение NDVI ниже критического порога на 30% и более в течение месяца). Сравнение производительности моделей является критически важным, поскольку от точности прогноза напрямую зависит экономическая целесообразность превентивных мер. Результаты оценки на отложенной тестовой выборке представлены ниже (табл. 2).

Таблица 2 - Метрики эффективности моделей машинного обучения в прогнозировании событий высокого риска

Модель	Accuracy	Precision	Recall	F1-score
Случайный лес (Random Forest)	0.941	0.852	0.881	0.866
Градиентный бустинг (XGBoost)	0.965	0.907	0.924	0.915
Сверточная нейронная сеть (CNN)	0.958	0.911	0.895	0.903

Анализ метрик показывает, что все три модели продемонстрировали высокую общую точность (Accuracy), превышающую 94%. Однако в задачах прогнозирования редких, но критически важных событий, более релевантными являются Precision (доля истинно положительных прогнозов среди всех положительных) и Recall (доля обнаруженных моделью рискованных событий от их общего числа). Модель градиентного бустинга показала наилучший сбалансированный результат по F1-score (0.915), что свидетельствует о ее превосходной способности не только корректно идентифицировать рискованные ситуации (высокий Recall), но и минимизировать количество ложных тревог (высокий Precision). Ложные тревоги влекут за собой необоснованные экономические затраты на превентивные меры, в то время как пропуск реальной угрозы (низкий Recall) может привести к катастрофическим потерям. Преимущество XGBoost, вероятно, связано с его эффективным механизмом последовательного исправления ошибок предыдущих деревьев и встроенной регуляризацией, что делает модель более устойчивой к переобучению на сложных и зашумленных геопространственных данных [Мкртчян, Потапов, 2025]. Сверточная нейронная сеть, хотя и показала высокую точность, оказалась несколько хуже в полноте охвата, что может быть связано с необходимостью еще больших объемов данных для ее полноценного обучения на пространственных зависимостях.

Для перевода полученных прогностических моделей на язык экономики и менеджмента была проведена оценка потенциального экономического ущерба, ассоциированного с прогнозируемым ростом экологических рисков. Мы смоделировали сценарий, в котором КИЭР в каждом регионе увеличивается на 5% относительно прогнозных значений 2025 года, и

оценили сопряженные с этим прямые финансовые потери для наиболее уязвимых секторов экономики (табл. 3). Эта оценка основана на эконометрических моделях, связывающих значения спутниковых индексов с историческими данными об урожайности, страховых выплатах и стоимости недвижимости [Кочергин, Якимчук, Куприянов, 2020].

В Регионе А основной удар приходится на сельское хозяйство, где потери могут составить почти 190 млн долларов из-за снижения урожайности и деградации земель. Для Региона Б, как и ожидалось, наиболее уязвим лесной сектор, где ущерб от снижения качества древесины и сокращения лесопокрытой площади оценивается более чем в 145 млн долларов. В урбанизированном Регионе В доминируют риски для секторов недвижимости и страхования, что связано с угрозами подтопления, ухудшением качества воздуха и ростом числа страховых случаев. Суммарный потенциальный ущерб по трем регионам от всего лишь 5%-го роста индекса риска превышает 850 млн долларов, что подчеркивает колоссальную экономическую значимость своевременного прогнозирования и управления этими угрозами.

Наконец, финальным этапом стало моделирование эффекта от применения различных превентивных стратегий смягчения рисков. Были рассмотрены три обобщенных сценария: «Интенсивная реинвестиция в экосистемы» (масштабные лесопосадки, восстановление водных объектов), «Внедрение ресурсосберегающих технологий» (точное земледелие, системы капельного орошения, «зеленое» строительство) и "Усиление регуляторного контроля" (ужесточение экологических норм, повышение штрафов) [Кочуров, Ивашкина, Еромолова, Фомина, 2022]. Для каждого сценария была оценена его потенциальная эффективность в виде снижения КИЭР и рассчитан коэффициент рентабельности инвестиций (BCR), как отношение предотвращенного ущерба к затратам на реализацию мер.

Сценарий интенсивной реинвестиции в экосистемы обеспечивает наибольшее абсолютное снижение уровня риска (0.085 пункта), однако он является и самым капиталоемким, что отражается в сравнительно невысоком коэффициенте рентабельности (1.92) [Вагизов, Потапов, 2023]. Это означает, что на каждый вложенный доллар возвращается 1.92 доллара в виде предотвращенных потерь. С другой стороны, сценарии, связанные с внедрением технологий и усилением контроля, демонстрируют значительно более высокую экономическую эффективность. Наиболее привлекательным с точки зрения возврата на инвестиции выглядит сценарий усиления регуляторного контроля ($BCR = 2.89$), однако его влияние на фактическое снижение риска является наименьшим. Сценарий внедрения ресурсосберегающих технологий представляет собой оптимальный баланс между существенным снижением риска и высокой экономической отдачей ($BCR = 2.85$).

Комплексный анализ всех полученных данных позволяет сформировать целостную картину. Идентификация зон с аномально высокой динамикой КИЭР (табл. 1) с помощью высокоточной прогностической модели (табл. 2) дает возможность точно применять наиболее рентабельные стратегии смягчения (табл. 4) для минимизации ожидаемого экономического ущерба в ключевых секторах (табл. 3). Например, для Региона Б, где наблюдается резкий рост риска из-за последствий пожаров, наиболее адекватной стратегией будет комбинация "Интенсивной реинвестиции" для восстановления лесного фонда и "Усиления контроля" для предотвращения новых возгораний. Для аграрного Региона А фокус должен быть смещен на "Внедрение ресурсосберегающих технологий", что напрямую снизит уязвимость основного сектора его экономики. Таким образом, предложенная методология трансформирует управление экологическими рисками из области интуитивных решений в сферу точного, количественно обоснованного стратегического планирования [Черниенко, Слишкин, Кулик, 2024]. Интеграция спутниковых данных и машинного обучения является не просто технологическим новшеством, а фундаментальным сдвигом парадигмы, позволяющим

капитализировать информацию о состоянии окружающей среды, превращая ее в действенный инструмент для сохранения экономического благополучия и обеспечения устойчивого развития [Казиева, Абжанова, Есекеева, Сагнаева, 2020; Ульянов, 2020].

Заключение

Проведенное исследование убедительно доказывает высокую эффективность и экономическую целесообразность интеграции спутниковых данных и методов машинного обучения для прогнозирования динамики и распределения экологических рисков. Разработанная методология позволяет перейти от пассивной констатации экологических проблем к активному, количественно обоснованному управлению ими. Способность модели градиентного бустинга предсказывать рисковые события с F1-мерой, достигающей 0.915, является ключевым достижением, открывающим возможность для своевременного принятия превентивных мер и значительного сокращения потенциальных потерь. Использование композитного индекса экологического риска (КИЭР) в качестве интегрального показателя позволило провести сопоставимый межрегиональный анализ и выявить территории с наиболее тревожной динамикой, требующие первоочередного внимания со стороны управляющих органов.

Экономический анализ продемонстрировал прямую и измеримую связь между ухудшением экологической обстановки и финансовыми потерями в ключевых секторах экономики. Моделирование показало, что даже умеренное, 5%-е увеличение уровня риска способно генерировать совокупный ущерб, исчисляемый сотнями миллионов долларов для исследуемых регионов. Это переводит дискуссию об охране окружающей среды из чисто гуманитарной плоскости в прагматичную сферу управления активами и минимизации финансовых угроз. Анализ сценариев смягчения последствий выявил, что стратегии, основанные на внедрении современных технологий и совершенствовании регуляторной политики, обладают наивысшей рентабельностью инвестиций, достигая показателя BCR на уровне 2.85-2.89. Это означает, что каждый доллар, вложенный в превентивные меры, способен предотвратить почти три доллара потенциального ущерба, что делает такие инвестиции высокопривлекательными как для государственного, так и для частного секторов.

Перспективы применения полученных результатов чрезвычайно широки. Предложенный инструментарий может быть использован страховыми компаниями для более точного актуарного расчета премий и оценки рисков по портфелям недвижимости и агрострахования. Для инвестиционных фондов и банков данная методология представляет собой инструмент для проведения ESG-анализа и оценки долгосрочной устойчивости проектов. Органы государственной власти могут использовать динамические карты рисков для оптимизации территориального планирования, размещения инфраструктуры и распределения бюджетных средств на природоохранные мероприятия. В корпоративном секторе данная система может стать основой для управления операционными рисками, оптимизации цепочек поставок и повышения устойчивости бизнеса к климатическим изменениям. Дальнейшее развитие методологии может включать интеграцию социально-экономических данных, использование более сложных архитектур нейронных сетей для учета долгосрочных временных зависимостей и создание публичных интерактивных платформ для информирования всех заинтересованных сторон. Внедрение подобных систем на национальном и глобальном уровнях способно кардинально изменить подход к управлению окружающей средой, сделав его проактивным, экономически эффективным и основанным на объективных данных.

Библиография

1. Вагизов М.Р., Потапов А.П. Технологии машинного обучения и обработки таксационных данных для визуализации геоинформационного моделирования лесных экосистем (часть 2) // Информация и космос. 2023. № 1. С. 148-156.
2. Заалишвили В.Б., Мельков Д.А., Фидарова М.И., Шманатов Г.В. Геоэкологические аспекты формирования интенсивности землетрясения на основе инструментальных данных // Геология и геофизика Юга России. 2024. Т. 14. № 2. С. 45-60.
3. Зорина И.Ю., Саханский Ю.В., Гаглоева И.Э. Методика прогнозирования и вероятностно-статистического анализа экологических рисков в альтернативной энергетике горного региона // Вестник Адыгейского государственного университета. Серия: Естественно-математические и технические науки. 2023. № 4 (331). С. 73-82.
4. Зупарова В.В., Маршакова А.Р. Интеллектуальные методы анализа данных в экологическом мониторинге атмосферного воздуха // Современные информационные технологии. 2025. № 41 (41). С. 51-55.
5. Казиева Г.Д., Абжанова А.Е., Есекеева М.Ж., Сагнаева С.К., Сембина Г.К. Биомониторингтегі деректерді зияткерлік талдаудың кейбір тәсілдері мен аспаптық құралдары // Вестник Евразийского национального университета имени Л.Н.Гумилева. Серия: Технические науки и технологии. 2020. № 1 (130). С. 50-58.
6. Капленкова П.А., Сивова А.Н. Предсказывание загрязнения атмосферного воздуха с помощью машинного обучения и PySpark // Наука и бизнес: пути развития. 2020. № 10 (112). С. 54-56.
7. Кочергин Г.А., Якимчук А.В., Куприянов М.А. Реализация имитационной модели оценки экологического риска на территории нефтедобычи // Экспозиция Нефть Газ. 2020. № 1 (74). С. 59-62.
8. Кочуров Б.И., Ивашкина И.В., Еромолова Ю.И., Фомина Н.В. Геоэкологический прогноз и использование энергоносителей // География и экология в школе XXI века. 2022. № 7. С. 3-15.
9. Мкртчян Ф.А., Потапов И.И. Контроль рисков при мониторинге стихийных бедствий и устойчивое развитие // Проблемы окружающей среды и природных ресурсов. 2025. № 6. С. 88-110.
10. Салимгареева В.Р. и др. Обзор использования систем дистанционного зондирования (ДЗЗ) для решения задач эколого-экономического прогнозирования (ЭЭП) // Естественные и технические науки. 2024. № 5 (192). С. 106-108.
11. Ульянов А.Е. Автоматизация анализа международных эколого-экономических систем на основе технологии машинного обучения // Электронный сетевой политематический журнал "Научные труды КубГТУ". 2020. № 6. С. 74-83.
12. Черниенко И.С., Слизкин А.Г., Кулик В.В. Применение методов машинного обучения для восстановления размерно-полового состава уловов краба-стригуна опилио // Известия ТИНРО. 2024. Т. 204. № 4. С. 1018-1034.
13. Черникова О.П., Князькина О.В., Хамитов Р.М. Проектирование системы предиктивной аналитики: технический, экономический и экологический аспекты // Экономика и предпринимательство. 2024. № 10 (171). С. 1198-1205.
14. Lofton M.E. et al. A modular curriculum to teach undergraduates ecological forecasting improves student and instructor confidence in their data science skills // Bioscience. 2024. Vol. 74. № 3. С. 209-222.
15. Yang B. et al. SSD model selection method based on machine learning algorithm // Journal of Physics: Conference Series. 2021. Т. 2005. № 1. С. 012082.

Forecasting the dynamics of the distribution of environmental risks based on the integration of satellite data and machine learning

Dmitrii S. Petrenko

Postgraduate Student,
Russian State Geological Prospecting
University named after Sergo Ordzhonikidze
117485, 23 Miklukho-Maklaya str., Moscow, Russian Federation;
e-mail: dim.petrenkos@yandex.ru

Abstract

The article is devoted to developing a methodology for forecasting environmental risks based on the integration of satellite data and machine learning algorithms. The aim of the study is to develop a tool that makes it possible to identify spatiotemporal patterns, build dynamic threat maps, and assess the economic consequences of growing environmental instability. The relevance of the work is driven by the rising frequency of extreme natural events, increasing economic losses, and the need to transition from reactive to proactive risk management strategies. The methodological foundation rests on a comprehensive approach that combines the acquisition of remote sensing data (Sentinel-1, Sentinel-2, Landsat, MODIS), the application of machine learning methods (Random Forest, XGBoost, CNN), and economic-statistical analysis. Predictors included satellite indices NDVI, NDMI, LST, as well as atmospheric pollution indicators (NO₂, aerosols). For modeling purposes, verified data on realized risk events (droughts, wildfires, floods) were used. Model quality was evaluated by Accuracy, Precision, Recall, and F1-score. Additionally, a composite Environmental Risk Index (CERI) was developed, aggregating key satellite indicators, which enabled comparable interregional analysis. The results showed that the gradient boosting algorithm (XGBoost) demonstrated the best balance between recall and precision ($F1 = 0.915$), delivering more reliable forecasts of rare yet consequential events. Analysis of CERI dynamics revealed that urbanized regions are characterized by the highest risk levels, whereas forested areas exhibit the strongest deterioration dynamics due to wildfires. The economic assessment showed that even a 5% increase in the index can cause aggregate losses exceeding \$850 million for the three pilot regions, primarily in the agriculture, forestry, real estate, and healthcare sectors. Modeling of preventive strategies indicated that the highest return on investment is delivered by resource-efficient technologies ($BCR = 2.85$) and strengthened regulatory oversight ($BCR = 2.89$), whereas large-scale environmental protection projects, despite their significant impact, are highly capital-intensive. In conclusion, it is emphasized that the integration of satellite monitoring and machine learning establishes a new level of environmental risk management, bringing environmental issues into the realm of strategic economic planning. The system developed has potential applications in insurance, investment analysis, spatial planning, and corporate governance.

For citation

Petrenko D.S. (2025) Prognozirovanie dinamiki raspredeleniya ekologicheskikh riskov na osnove integratsii sputnikovykh dannykh i mashinnogo obucheniya [Forecasting the dynamics of the distribution of environmental risks based on the integration of satellite data and machine learning]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 15 (7A), pp. 183-192. DOI: 10.34670/AR.2025.40.20.019

Keywords

Environmental risks, remote sensing, machine learning, environmental risk index, forecasting

References

1. Chernienko I.S., Slizkin A.G., Kulik V.V. (2024) Primenenie metodov mashinnogo obucheniya dlya vosstanovleniya razmemo-polovogo sostava ulovov kraba-striguna opilio [Application of machine learning methods for reconstructing the size-sex composition of snowcrab catches]. *Izvestiya TINRO* [Bulletin of TINRO], 204(4), pp. 1018-1034.
2. Chernikova O.P., Knyaz'kina O.V., Khamitov R.M. (2024) Proektirovanie sistem prediktivnoy analitiki: tekhnicheskii, ekonomicheskii i ekologicheskii aspekty [Designing a predictive analytics system: technical, economic and environmental aspects]. *Ekonomika i predprinimatel'stvo* [Economics and Entrepreneurship], 10(171), pp. 1198-1205.

3. Kaplenkova P.A., Sivova A.N. (2020) Predskazyvanie zagryazneniya atmosfery vozdukh s pomoshch'yu mashinnogo obucheniya i PySpark [Predicting atmospheric air pollution using machine learning and PySpark]. *Nauka i biznes: puti razvitiya* [Science and Business: Development Paths], 10(112), pp. 54-56.
4. Kazieva G.D., Abzhanova A.E., Eseeva M.Zh., Sagnaeva S.K., Sembina G.K. (2020) Biomonitoring tegi derekterdi ziyatkerlik taldaudyng keibir tasilder men aspattyk kuraldary [Some methods and tools for intelligent analysis of biomonitoring data]. *Vestnik Evraziyskogo natsional'nogo universiteta imeni L.N. Gumileva. Seriya: Tekhnicheskie nauki i tekhnologii* [Bulletin of the L.N. Gumilyov Eurasian National University. Series: Technical Sciences and Technologies], 1(130), pp. 50-58.
5. Kochergin G.A., Yakimchuk A.V., Kupriyanov M.A. (2020) Realizatsiya imitatsionnoy modeli otsenki ekologicheskogo riska na territorii nefte dobychi [Implementation of a simulation model for environmental risk assessment in oil production areas]. *Ekspozitsiya Neft' Gaz* [Exposition Oil Gas], 1(74), pp. 59-62.
6. Kochurov B.I., Ivashkina I.V., Eromolova Yu.I., Fomina N.V. (2022) Geoekologicheskiy prognoz i ispol'zovanie energonositeley [Geoecological forecast and use of energy resources]. *Geografiya i ekologiya v shkole XXI veka* [Geography and Ecology in the School of the 21st Century], 7, pp. 3-15.
7. Lofton M.E. et al. (2024) A modular curriculum to teach undergraduates ecological forecasting improves student and instructor confidence in their data science skills. *Bioscience*, 74(3), pp. 209-222.
8. Mkrtchyan F.A., Potapov I.I. (2025) Kontrol' riskov pri monitoringe stikhiynykh bedstviy i ustoychivoe razvitie [Risk control in natural disaster monitoring and sustainable development]. *Problemy okruzhayushchey sredy i prirodnnykh resursov* [Environmental and Natural Resource Problems], 6, pp. 88-110.
9. Salimgareeva V.R. et al. (2024) Obzor ispol'zovaniya sistem dstantsionnogo zondirovaniya (DZZ) dlya resheniya zadach ekologo-ekonomicheskogo prognozirovaniya (EEP) [Review of the use of remote sensing systems for solving ecological and economic forecasting problems]. *Estestvennye i tekhnicheskie nauki* [Natural and Technical Sciences], 5(192), pp. 106-108.
10. Ulyankin A.E. (2020) Avtomatizatsiya analiza mezhdunarodnykh ekologo-ekonomicheskikh sistem na osnove tekhnologii mashinnogo obucheniya [Automation of international ecological and economic systems analysis based on machine learning technology]. *Elektronnyy setevoy politematicheskyy zhurnal "Nauchnye trudy KubGTU"* [Electronic Network Multidisciplinary Journal "Scientific Works of KubSTU"], 6, pp. 74-83.
11. Vagizov M.R., Potapov A.P. (2023) Tekhnologii mashinnogo obucheniya i obrabotki taksatsionnykh dannykh dlya vizualizatsii geoinformatsionnogo modelirovaniya lesnykh ekosistem (chast' 2) [Machine learning technologies and processing of forest inventory data for visualization of geoinformation modeling of forest ecosystems (part 2)]. *Informatsiya i kosmos* [Information and Space], 1, pp. 148-156.
12. Yang B. et al. (2021) SSD model selection method based on machine learning algorithm. *Journal of Physics: Conference Series*, 2005(1), pp. 012082.
13. Zaalishvili V.B., Mel'kov D.A., Fidarova M.I., Shmanatov G.V. (2024) Geoekologicheskie aspekty formirovaniya intensivnosti zemletreseniya na osnove instrumental'nykh dannykh [Geoecological aspects of earthquake intensity formation based on instrumental data]. *Geologiya i geofizika Yuga Rossii* [Geology and Geophysics of the South of Russia], 14(2), pp. 45-60.
14. Zorina I.Yu., Sakhanskiy Yu.V., Gagloeva I.E. (2023) Metodika prognozirovaniya i veroyatnostno-statisticheskogo analiza ekologicheskikh riskov v al'ternativnoy energetike gornogo regiona [Methodology for forecasting and probabilistic-statistical analysis of environmental risks in alternative energy of a mountain region]. *Vestnik Adygeyskogo gosudarstvennogo universiteta. Seriya: Estestvenno-matematicheskie i tekhnicheskie nauki* [Bulletin of the Adyge State University. Series: Natural-Mathematical and Technical Sciences], 4(331), pp. 73-82.
15. Zuparova V.V., Marshakova A.R. (2025) Intellekturnye metody analiza dannykh v ekologicheskom monitoringe atmosfery vozdukh [Intelligent data analysis methods in environmental monitoring of atmospheric air]. *Sovremennye informatsionnye tekhnologii* [Modern Information Technologies], 41(41), pp. 51-55.