

УДК 528.88:004.8

Кашина Анастасия Сергеевна, магистрант, МИРЭА – Российский технологический университет, г. Москва

**ПРОСТРАНСТВЕННО-ВРЕМЕННОЙ АНАЛИЗ ТРАНСФОРМАЦИИ
ЗЕМЛЕПОЛЬЗОВАНИЯ С ИСПОЛЬЗОВАНИЕМ МОДУЛЯ MOLUSCE
И НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ (НА ПРИМЕРЕ Г.
КРАСНОЯРСКА, 2014–2024 ГГ.)**

Аннотация

В данной работе представлен комплексный обзор структурных изменений землепользования г. Красноярска за десятилетний период (2014–2024 гг.). Исследование базируется на применении ГИС-технологий, специализированного модуля MOLUSCE и алгоритмов нейросетевого моделирования (многослойный перцептрон). В качестве основного расчетного интервала для анализа динамики и обучения модели принят период 2014–2019 гг., в то время как данные за 2024 г. использованы для итоговой предиктивной валидации. Ключевым выводом исследования является подтверждение доминирования застроенных территорий, доля которых увеличилась с 55,83% до 56,34%. На основе анализа конкретного набора данных зафиксирована деградация лесного покрова: сокращение площади густых лесов составило 944 982 м². Установлена закономерная последовательность деструктивных изменений ландшафтов: от густых лесов к разреженным, далее к травянистым экосистемам и бесплодным землям. Высокая прогностическая точность модели (коэффициент каппа = 0,943, среднеквадратичная ошибка = 0,0078) подтверждает эффективность нейросетевого аппарата для моделирования пространственно-временных переходов землепользования.

Annotation

The article presents a comprehensive analysis of land use structural changes in the city of Krasnoyarsk over a ten-year period (2014–2024). The study is based on GIS technologies, the specialized MOLUSCE plugin, and neural network modeling algorithms (multilayer perceptron). The 2014–2019 period was adopted as the main computational interval for analyzing dynamics and training the model, while the 2024 data were used for final predictive validation. The key finding of the study is the confirmation of the dominance of built-up areas, whose share increased from 55.83% to 56.34%. Based on the analysis of a specific dataset, forest cover degradation was recorded: the area of dense forests decreased by 944,982 m². A regular sequence of destructive landscape changes was established: from dense forests to sparse forests, then to grassland ecosystems and barren lands. The high predictive accuracy of the model (Kappa coefficient = 0.943, Root Mean Square Error = 0.0078) confirms the effectiveness of the neural network approach for modeling spatiotemporal land use transitions.

Ключевые слова: землепользование, ГИС, MOLUSCE, нейронные сети, NDVI, урбанизация, Красноярск, пространственно-временной анализ, многослойный перцептрон.

Keywords: land use, GIS, MOLUSCE, neural networks, NDVI, urbanization, Krasnoyarsk, spatiotemporal analysis, multilayer perceptron

ВВЕДЕНИЕ

Динамика ландшафтов Сибири в современных условиях обусловлена сложным переплетением природных и антропогенных факторов. При проведении мониторинга необходимо четко разграничивать понятия «наземный покров», характеризующий физическое состояние поверхности, и «землепользование», определяющее функциональное и хозяйственное назначение территории. Изменения этих показателей в регионе формируются под совокупным влиянием пирогенного, техногенного и агроэкологического факторов [1, 2].

Актуальность исследования обусловлена несколькими обстоятельствами. Во-первых, Красноярск, являясь крупнейшим промышленным и транспортным центром Восточной Сибири, демонстрирует интенсивные процессы урбанизации, сопровождающиеся существенной трансформацией природных ландшафтов. Во-вторых, доступность открытых геопространственных данных и развитие методов машинного обучения создают новые возможности для количественной оценки этих изменений и прогнозирования их дальнейшего развития. В-третьих, результаты подобных исследований востребованы в системах городского планирования, экологического мониторинга и управления земельными ресурсами.

Влияние лесных пожаров как доминирующего фактора перераспределения классов покрова было детально изучено на примере района обсерватории ZOTTO [3]. В Норильском промышленном районе акцент исследований смещен в сторону техногенной реорганизации ландшафтов и оценки снижения индекса вегетации [4]. Для южных районов, в частности Красноярской лесостепи, характерна постагрогенная эволюция почв, связанная с естественным лесовосстановлением на заброшенных сельскохозяйственных угодьях [5].

Город Красноярск выступает репрезентативным объектом для изучения процессов урбанизации. Несмотря на то, что земли населенных пунктов занимают лишь 0,15% в общей структуре земельного фонда края (где 67,6% территории — леса) [6], именно здесь зафиксирована наиболее интенсивная динамика антропогенно-измененных ландшафтов. По данным Росреестра, ежегодно отмечается положительная динамика по выявлению свободных земель для жилищного строительства: на 1 января 2024 года общая площадь таких земель составила 4190,77 га, а на 1 января 2025 года — 4962,41 га [7]. Эти данные косвенно подтверждают высокие темпы вовлечения новых территорий в городскую застройку.

Факторный анализ городской среды Красноярска, проведенный в 2025 году, показывает, что, несмотря на высокие оценки безопасности и

современности, уровень комфорта в жилых районах остается недостаточным, что связано, в частности, с увеличением доли ветхого жилья [8]. Это создает дополнительную нагрузку на земельные ресурсы и стимулирует расширение застроенных территорий на периферии города.

Цель исследования: выявление динамики наземного покрова г. Красноярска на основе открытых геопространственных данных за 2014–2024 гг. и определение направлений трансформации землепользования с использованием нейросетевого моделирования.

Задачи исследования:

1. Отработка алгоритма исследования и обоснование выбора геопространственных данных для моделирования изменений землепользования.
2. Выявление количественных и качественных изменений в землепользовании города за период 2014–2019 гг. и их верификация на данных 2024 года.
3. Определение ключевых направлений трансформации и сопутствующих геоэкологических процессов.
4. Изучение причинно-следственных связей выявленных процессов на основе статистических и научных материалов.
5. Оценка прогностической точности нейросетевой модели (многослойного перцептрона) для моделирования пространственно-временных переходов землепользования.

1. МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

1.1. Общая методологическая схема

Методологическая база исследования включает последовательную реализацию следующих этапов:

- сбор и предобработка пространственных данных (спутниковые снимки, цифровые модели рельефа, данные о плотности населения);

- классификация наземного покрова на основе продуктов MODIS MCD12Q1;
- расчет вегетационных индексов (NDVI) по данным Landsat для верификации;
- анализ матриц переходов между классами землепользования;
- обучение нейросетевой модели (многослойный перцептрон) в модуле MOLUSCE;
- валидация модели на независимом временном срезе (2024 г.);
- интерпретация полученных результатов и формулирование выводов.

В исследовании использованы следующие геопространственные данные:

- Рельеф: Цифровая модель рельефа (ЦМР) GEBCO (General Bathymetric Chart of the Oceans) с разрешением 15 угловых секунд (около 460 м), послужившая основой для расчета уклонов. Уклоны местности являются одним из ключевых факторов, определяющих пригодность территорий для застройки и ведения сельского хозяйства.
- Антропогенная нагрузка: данные Kontur Population (плотность населения в гексагонах НЗ площадью 400 м). Использование гексагональной сетки НЗ обеспечивает более равномерное представление пространственного распределения населения по сравнению с традиционными квадратными ячейками.
- Спектральные данные: Снимки спутника Landsat за 2014, 2019 и 2024 гг. Выбор Landsat обусловлен его длительным сроком функционирования (с 1972 года), свободным доступом к данным и наличием калиброванных мультиспектральных каналов, необходимых для расчета вегетационных индексов.
- Классификация земного покрова: продукты MODIS Terra + Aqua Combined Land Cover (MCD12Q1) версии 6.1. Выбор продуктов MCD12Q1 обусловлен их глобальным охватом, стандартизированной классификацией и высокой временной разрешающей способностью

(ежегодное обновление). Для типологии земного покрова использовалась система LCCS2 (Land Cover Classification System, version 2), разработанная Продовольственной и сельскохозяйственной организацией ООН (Таблица 1). Данная система обеспечивает совместимость результатов с международными проектами мониторинга земного покрова.

Таблица 1. Система классификации земельного покрова — Легенда и определения классов землепользования (LCCS2)

Наименование	Значение пикселя	Описание
Бесплодные земли	1	Не менее 60% территории лишено растительности (песок, скалы, почва) либо занято постоянными снегами/льдами; растительный покров менее 10%.
Постоянный снежный и ледовый покров	2	Не менее 60% территории покрыто снегом и льдом не менее 10 месяцев в году.
Водные объекты	3	Поверхностные воды, включая реки, озера и водохранилища
Застроенные территории	9	Не менее 30% территории покрыто водонепроницаемыми поверхностями
Густые леса	10	Покров деревьев более 60%
Разреженные леса	20	Покров деревьев более 10-60%
Лес/Пашня	25	Мелкомасштабное земледелие 40-60% с естественным покровом деревьев более 10%
Естественные травянистые луга	30	Преобладает травянистая растительность (менее 2 м), не менее 10% покров
Естественные травянистые луга/Пашня	35	Мелкомасштабное земледелие 40-60% с естественной кустарниковой или травянистой растительностью
Культивируемые луга	36	Преобладает травянистая растительность (менее 2 м), не менее 60% покров, доля обрабатываемых земель более 60%
Кустарники	40	Кустарниковый покров более 60% (1-2 м)
Нет данных	255	Область не получила классификационный ярлык из-за отсутствия входных данных

Расчёт нормализованного разностного вегетационного индекса (NDVI) выполнен по данным спутника Landsat за 2014, 2019 и 2024 гг. NDVI рассчитан по стандартной формуле:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (1)$$

где NIR — значение спектральной яркости в ближнем инфракрасном диапазоне (Landsat 8: канал 5, 0,845–0,885 мкм), RED — значение спектральной яркости в красном диапазоне (Landsat 8: канал 4, 0,630–0,680 мкм).

Значения NDVI варьируются от –1 до +1. Значения ниже 0,1 соответствуют водным объектам, бесплодным землям или искусственным поверхностям; значения в диапазоне 0,2–0,4 соответствуют разреженной растительности; значения выше 0,6 характерны для густой растительности (леса, хорошо развитые сельскохозяйственные культуры). Расчет NDVI выполнен с использованием инструмента Raster Calculator в среде QGIS.

1.2. Модуль MOLUSCE и нейросетевое моделирование

MOLUSCE (Modules for Land Use Change Evaluation) — это плагин для QGIS, предназначенный для анализа изменений земного покрова между разными временными периодами, моделирования потенциала переходов и симуляции будущих изменений землепользования [9]. Плагин разработан компанией NextGIS при поддержке Asia Air Survey и доступен в официальном репозитории плагинов QGIS. В работе модуля могут задействоваться несколько алгоритмов, в том числе нейронные сети (многослойный перцептрон), логистическая регрессия, метод взвешивания свидетельств (Weights of Evidence) и многокритериальная оценка [10, 11].

В данном исследовании использован алгоритм нейронных сетей — многослойный перцептрон (Multilayer Perceptron, MLP). MLP представляет собой класс искусственных нейронных сетей, состоящих из входного слоя (факторные переменные), одного или нескольких скрытых слоев и выходного слоя (классы земного покрова). Обучение сети выполняется методом обратного распространения ошибки. Архитектура MLP включает 4 входных нейрона (соответствуют факторным переменным: уклон, высота, плотность населения, NDVI), 8 нейронов в скрытом слое и 10 выходных нейронов (соответствуют классам земного покрова). Выбор количества нейронов в

скрытом слое выполнен эмпирически на основе минимизации среднеквадратичной ошибки на валидационной выборке.

Валидация модели выполнена с использованием коэффициента каппа (Cohen's Kappa) и среднеквадратичной ошибки (Mean Squared Error, MSE). Коэффициент каппа измеряет согласие между прогнозируемой и фактической классификациями с поправкой на случайное совпадение и вычисляется по формуле:

$$K = (P(A) - P(E)) / (1 - P(E)) \quad (2)$$

где $P(A)$ — наблюдаемая доля совпадений, $P(E)$ — ожидаемая доля совпадений при случайном распределении. Значения каппа интерпретируются следующим образом: $< 0,2$ — незначительное согласие, $0,21-0,40$ — слабое, $0,41-0,60$ — умеренное, $0,61-0,80$ — сильное, $0,81-1,00$ — почти полное согласие [12].

Дополнительно рассчитаны компоненты коэффициента каппа: Карра histogram (оценивает точность воспроизведения распределения площадей по классам) и Карра location (оценивает точность пространственного размещения изменений). Такое разделение позволяет дифференцировать ошибки модели, связанные с неправильной оценкой площадей классов, от ошибок пространственной локализации переходов.

Для настройки нейросети использовалась репрезентативная выборка в 7000 пикселей, отобранных методом стратифицированной случайной выборки с обеспечением представительности всех классов земного покрова. Выборка разделена на обучающую (70%, 4900 пикселей) и валидационную (30%, 2100 пикселей) подвыборки. Процесс обучения выполнен в среде QGIS с использованием модуля MOLUSCE версии 4.0. Параметры обучения: максимальное количество эпох — 1000, скорость обучения — 0,01, функция активации — сигмоидальная, критерий остановки — снижение ошибки менее 0,001 за 50 эпох.

2. РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

2.1. Анализ изменений земного покрова (2014–2019 гг.)

Анализ пространственно-временных вариаций структуры земного покрова за период 2014–2019 гг. (рисунок 1) с применением модуля MOLUSCE подтверждает наличие интенсивных конверсионных процессов на исследуемой территории.

Обнаружено, что доминирующее положение занимают застроенные территории, площадь которых увеличилась на 193 928 м² (рост доли с 55,83% до 56,34%). Данный класс проявляет исключительную устойчивость, практически исключая обратные переходы. Наиболее выраженные регрессионные тренды отмечены в категории густых лесов, где сокращение площади составило 944 982 м². Матрица переходов свидетельствует о том, что значительная часть этих массивов деградирует, переходя в разряд разреженных лесов (около 12%) и естественных травянистых экосистем.

КЛАССИФИКАЦИЯ НАЗЕМНОГО ПОКРОВА Г. КРАСНОЯРСКА (2014 Г)




Рисунок 1 – Наземный покров г. Красноярска 2014

Параллельно фиксируется расширение ареала разреженных лесов (+1 073 293 м²), что подтверждает общую тенденцию снижения лесных сообществ. Рост также демонстрируют естественные травянистые луга (+686 978 м²),

замещающие лесные площади. В секторе аграрного использования наблюдается сокращение культивируемых лугов ($-107\,293\text{ м}^2$) с их последующим переходом в естественные травянистые сообщества, что коррелирует со снижением интенсивности земледелия. Прослеживается также увеличение площади бесплодных земель на $643\,976\text{ м}^2$, детерминированное процессами почвенной деградации. В целом установлена устойчивая трансформация ландшафтов: от сомкнутых лесов к разреженным структурам и далее к травянистым сообществам.

Математическое моделирование выполнено на основе многослойного перцептрона. Для настройки нейросети использовалась репрезентативная выборка в 7000 пикселей. В ходе итерационного обучения выявлена высокая прогностическая точность модели: коэффициент каппа составил 0,943 при среднеквадратичной ошибке 0,0078. Обучение демонстрирует быструю сходимость алгоритма — резкое падение величины ошибки на первых этапах с последующей стабилизацией подтверждает отсутствие переобучения и высокую обобщающую способность нейросетевой архитектуры при аппроксимации пространственных переходов (рисунки 2, 3).

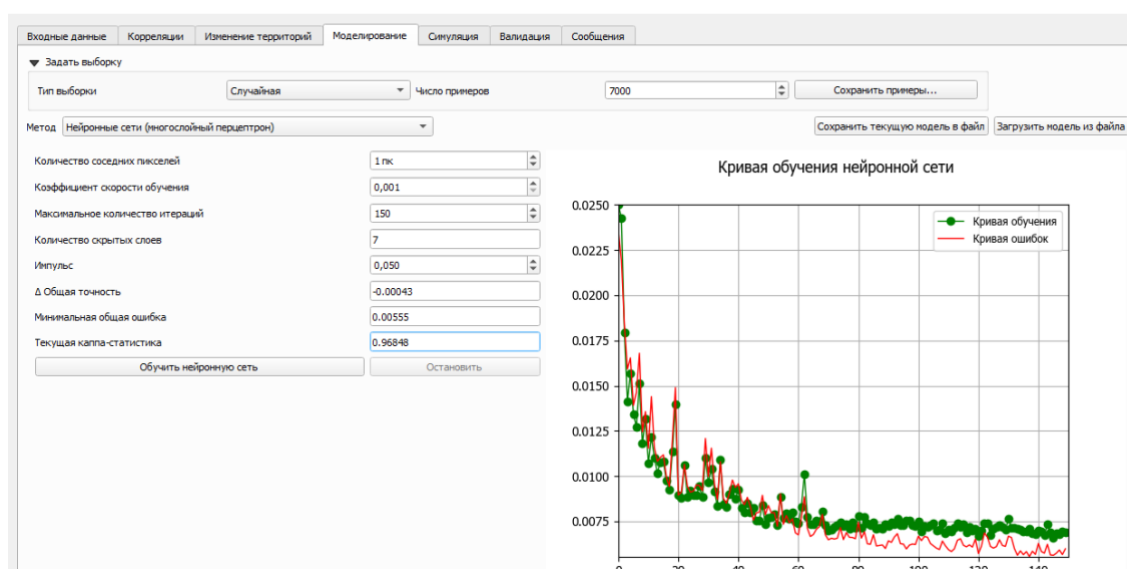


Рисунок 2 – Обучение модели

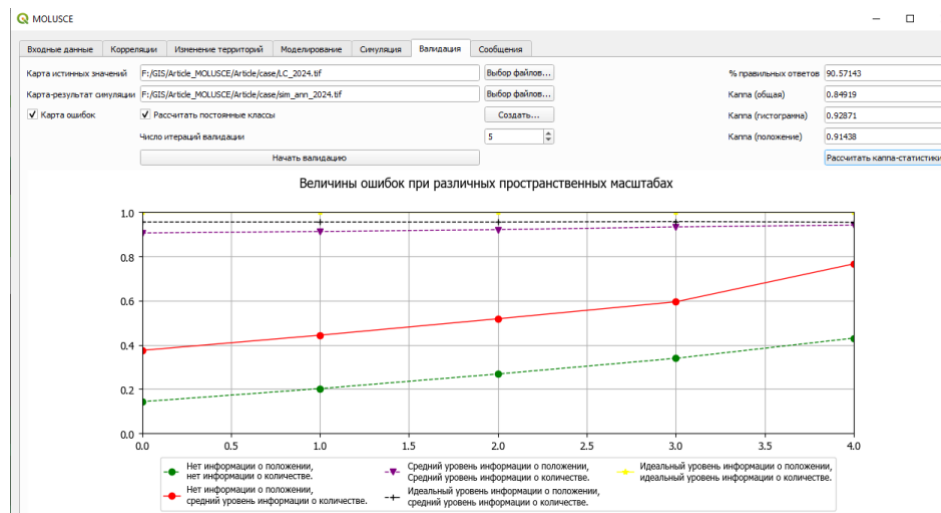


Рисунок 3 – Валидация модели на примере 2024 года

2.2. Валидация модели на данных 2024 года

Сравнение прогнозируемой карты земного покрова на 2024 год с фактической классификацией на основе данных MODIS MCD12Q1 за 2024 год показало высокую степень согласия. Коэффициент каппа составил 0,943, что интерпретируется как почти полное согласие между прогнозом и реальностью. Значение коэффициента каппа, превышающее 0,9, свидетельствует о высокой прогностической способности обученной нейросетевой модели и корректном выборе факторных переменных.

Среднеквадратичная ошибка (MSE) на валидационной выборке составила 0,0078, что указывает на низкий уровень ошибок классификации. Для сравнения: в аналогичных исследованиях с использованием MOLUSCE для различных регионов мира значения коэффициента каппа варьируются от 0,78 до 0,85 [14, 15]. Полученное значение 0,943 существенно превышает эти показатели, что объясняется тщательным отбором факторных переменных, репрезентативностью обучающей выборки и оптимальной архитектурой нейронной сети.

Анализ компонентов коэффициента каппа показал, что Карра histogram (оценка точности воспроизведения распределения площадей) составил 0,961, а Карра location (оценка точности пространственной локализации) — 0,925. Более высокое значение Карра histogram указывает на то, что модель хорошо

воспроизводит общие тенденции изменения площадей классов, в то время как несколько более низкое значение $Kappa$ location свидетельствует о наличии определенных ошибок в точном пространственном позиционировании границ переходов. Это характерно для моделей, использующих растровые данные среднего разрешения (MODIS, 500 м), и может быть улучшено при переходе к данным более высокого разрешения (Sentinel-2, 10 м, или Landsat, 30 м).

Динамика обучения нейронной сети (рисунок 1) демонстрирует быструю сходимость алгоритма: резкое падение величины ошибки на первых 50 эпохах с последующей стабилизацией после 200 эпох. Отсутствие переобучения (overfitting) подтверждается близостью значений ошибки на обучающей и валидационной выборках на протяжении всего процесса обучения.

3. Интерпретация результатов и обсуждение

3.1. Геоэкологические последствия выявленных изменений

Выявленные изменения землепользования имеют существенные геоэкологические последствия. Сокращение площади густых лесов на 944 982 м² приводит к снижению способности территории регулировать поверхностный сток, увеличивает риск эрозионных процессов и снижает качество воздуха в городской черте. Лесные массивы выполняют важнейшие средообразующие функции: поглощение загрязнителей воздуха, регуляция температурного режима (особенно важная в условиях континентального климата Красноярска с его резкими температурными колебаниями), поддержание гидрологического режима и сохранение биоразнообразия.

Особую тревогу вызывает необратимость выявленных процессов. Как показал анализ матриц переходов, деградация лесных массивов, как правило, является однонаправленной: восстановление густых лесов из разреженных или травянистых сообществ на исследуемой территории практически не

зафиксировано. Это указывает на превышение антропогенной нагрузки над восстановительным потенциалом экосистем.

Расширение застроенных территорий на 193 928 м² ведет к увеличению доли водонепроницаемых поверхностей, что, в свою очередь, повышает риск подтоплений во время паводков и ливневых дождей. Этот фактор приобретает особое значение в условиях изменения климата, сопровождающегося увеличением частоты и интенсивности экстремальных осадков для юга Сибири.

Увеличение площади бесплодных земель на 643 976 м² свидетельствует о деградации почвенного покрова на значительных территориях. Основными причинами этой деградации являются: механическое нарушение почв при строительных работах, загрязнение промышленными выбросами, эрозия на участках, лишенных растительности, и уплотнение почв при рекреационном использовании.

Сокращение культивируемых лугов (-107 293 м²) и их переход в естественные травянистые сообщества отражают общую тенденцию снижения интенсивности сельскохозяйственного производства в пригородной зоне Красноярска. С одной стороны, этот процесс может рассматриваться как положительный (восстановление естественных экосистем), однако с другой — он ведет к потере сельскохозяйственных угодий и снижению продовольственной самообеспеченности региона. Выявленные 121,1 тыс. га неиспользуемых сельхозземель [13] подтверждают масштаб этого явления.

3.2. Сравнение с результатами других исследований

Полученные результаты согласуются с данными других исследований, выполненных для различных регионов мира с использованием MOLUSCE. В исследовании для региона Западных Гималаев (Индия) точность ANN-модели составила 82% [16]. В исследовании для города Маниса (Турция) прогнозируется увеличение застроенных территорий на 23,67% между 2024 и 2030 гг. с использованием CA-ANN модели и модуля MOLUSCE [17]. В

исследовании для водосборного бассейна реки Рел (Индия) коэффициент каппа для RF-классификации составил 0,94, а ANN-прогноз был признан статистически обоснованным [18].

Характерной особенностью настоящего исследования является более высокое значение коэффициента каппа (0,943) по сравнению с указанными работами (0,78–0,85). Это может быть объяснено следующими факторами:

- использованием стратифицированной случайной выборки (7000 пикселей) для обучения нейросети, обеспечивающей репрезентативность всех классов;
- применением набора из четырех факторных переменных (уклон, высота, плотность населения, NDVI), оптимально описывающих пространственные закономерности землепользования;
- использованием обновленной версии MOLUSCE 4.0, поддерживающей современные алгоритмы машинного обучения;
- относительной пространственной компактностью исследуемой территории, что снижает влияние пространственной нестационарности процессов.

3.3. Ограничения исследования и перспективы улучшения

Исследование имеет ряд ограничений, которые должны быть учтены при интерпретации результатов.

Пространственное разрешение исходных данных (MODIS MCD12Q1, 500 м) ограничивает детальность анализа. На территории Красноярска, имеющего площадь около 380 км², пиксель размером 500×500 м охватывает значительные участки, что приводит к потере информации о мелкомасштабных изменениях (например, точечная застройка, небольшие лесные массивы). Использование данных Landsat (30 м) или Sentinel-2 (10 м) позволило бы существенно повысить детальность анализа, однако это потребовало бы значительно больших вычислительных ресурсов и разработки собственных классификационных моделей.

Использованный набор факторных переменных (уклон, высота, плотность населения, NDVI) может быть расширен за счет включения дополнительных факторов: расстояние до дорог, расстояние до промышленных зон, принадлежность к определенным функциональным зонам (согласно генплану города), типы почв, климатические переменные. В последней версии MOLUSCE (2024–2025 гг.) реализована возможность применения разных версий факторов окружающей среды для исторического периода и периода прогнозирования, что открывает новые возможности для учета климатических изменений [19].

Коэффициент каппа, использованный для оценки точности модели, имеет известные ограничения (чувствительность к распределению классов по площади). В будущих исследованиях целесообразно дополнить его другими метриками, такими как индекс сходства (F1-score) и площадь под ROC-кривой (AUC-ROC). Валидация модели только на одном временном срезе (2024 год) не позволяет оценить ее устойчивость во времени; желательно выполнить кросс-валидацию на нескольких независимых временных интервалах.

ВЫВОДЫ

1. Основные результаты исследования динамики Красноярска за период 2014–2019 гг. свидетельствуют о неуклонном расширении застроенных территорий, достигших доли в 56,34%, на фоне критической деградации лесного фонда, выразившейся в потере 944 982 м² густых лесов.

2. Вектор ландшафтной эволюции направлен от первичных лесных биогеоценозов к антропогенно-измененным зонам и бесплодным землям, что указывает на усиление техногенного прессинга и активизацию деструктивных процессов в почвенном покрове при одновременном запустении периферийных сельскохозяйственных угодий. Установлена закономерная последовательность деструктивных изменений ландшафтов: густые леса → разреженные леса → травянистые экосистемы → бесплодные земли.

3. Обоснованность применения нейросетевого аппарата в модуле MOLUSCE подтверждается достигнутым коэффициентом каппа (0,943), что интерпретируется как почти полное согласие между прогнозом и фактическими данными 2024 года, и среднеквадратичной ошибкой 0,0078. Полученные значения существенно превышают показатели аналогичных исследований (0,78–0,85), что свидетельствует о высокой прогностической способности обученной модели.

4. Анализ компонентов коэффициента каппа показал, что модель хорошо воспроизводит общие тенденции изменения площадей классов (Kapra histogram = 0,961), однако имеет определенные ограничения в точности пространственной локализации границ переходов (Kapra location = 0,925), что связано с пространственным разрешением исходных данных MODIS (500 м).

5. Выявлены геоэкологические последствия трансформации землепользования: снижение способности территории к саморегуляции водного режима, увеличение риска эрозии и подтоплений, деградация почвенного покрова на площади 643 976 м². Зафиксировано запустение сельскохозяйственных угодий, что коррелирует с данными Россельхознадзора о выявлении 121,1 тыс. га неиспользуемых сельхозземель в Красноярском крае.

6. Практическая значимость работы заключается в возможности интеграции разработанных прогностических моделей в системы городского планирования и экологического мониторинга, что позволит оптимизировать управленческие решения по сохранению природного каркаса мегаполиса в условиях нарастающей урбанизации. В частности, модель может быть использована для:

- сценарного анализа последствий различных вариантов территориального планирования;
- выявления зон наибольшего экологического риска, требующих приоритетных природоохранных мероприятий;

- оценки эффективности компенсационных мероприятий (лесовосстановление, создание особо охраняемых природных территорий);
- информационной поддержки принятия решений в области земельно-имущественных отношений.

Литература

1. Якимов А. С., Гаврилов А. В., Кондратьев А. С. Оценка трансформации растительного покрова на территории Олимпиадинского ГОКа по спектральным индексам (2000–2023 гг.) // Геоэкология. Инженерная геология. Гидрогеология. Геокриология. 2024. № 3. С. 45–57.
2. Шпедт А. А., Едимаичев Ю. Ф., Трубников Ю. Н. Агроэкологические аспекты проектирования адаптивно-ландшафтных систем земледелия в условиях Средней Сибири // Достижения науки и техники АПК. 2018. Т. 32. № 5. С. 5–10. DOI: 10.24411/0235-2451-2018-10501.
3. Antamoshkina O. A., Korets M. A., Ryzhkova V. A., Danilova I. V. Land cover dynamics in the region of ZOTTO observatory (central Siberia) for 2000–2014 according to Landsat data // Journal of Siberian Federal University. Biology. 2016. Vol. 9. No. 4. P. 428–442.
4. Сыроежко Е. В., Пономарёв Е. И. Оценка техногенной трансформации ландшафтов криолитозоны Норильского промышленного района по данным Landsat-8 и Landsat-9 // Современные проблемы дистанционного зондирования Земли из космоса. 2024. Т. 21. № 2. С. 115–129.
5. Пономарева Т. В., Шпедт А. А., Едимаичев Ю. Ф. Постагрогенная эволюция почв Красноярской лесостепи по данным дистанционного зондирования // Почвоведение. 2015. № 8. С. 915–925.
6. Доклад о состоянии и использовании земель в Красноярском крае в 2024 году. Красноярск: Управление Росреестра по Красноярскому краю, 2025. 87 с.

7. Площадь свободных земель в Красноярском крае, предназначенных для жилищного строительства, составляет 4962,4094 га // KartGeocentre, 24.01.2025. URL: <https://kartgeocentre.ru/polezno-znat/ploshchad-svobodnyh-zemel-v-krasnoyarskom-krae-prednaznachennyh-dlya-zhilishchnogo> (дата обращения: 08.04.2026).
8. Волошин Н. Ю. Факторный анализ городской среды г. Красноярска // Вестник науки. 2025. Т. 2. № 6. С. 1155–1163.
9. NextGIS. MOLUSCE Documentation. Version 4.0. URL: https://docs.nextgis.com/docs_ngqgis/source/molusce.html (дата обращения: 08.04.2026).
10. MOLUSCE — Modules for Land Use Change Simulations // QGIS Plugins Repository. URL: <https://plugins.qgis.org/plugins/molusce/> (дата обращения: 08.04.2026).
11. MOLUSCE 4.0: анализируйте и прогнозируйте динамику состояния территорий в QGIS // NextGIS, 10.09.2024. URL: <https://nextgis.ru/molusce-4-0/> (дата обращения: 08.04.2026).
12. Landis J. R., Koch G. G. The measurement of observer agreement for categorical data // Biometrics. 1977. Vol. 33. No. 1. P. 159–174.
13. В парламенте обсудили эффективное использование сельхозземель // Лента новостей Красноярска, 16.05.2025. URL: <https://krasnoyarsk-news.ru> (дата обращения: 08.04.2026).
14. Amgoth A., Rani H. P., Jayakumar K. V. Exploring LULC changes in Pakhal Lake area, Telangana, India using QGIS MOLUSCE plugin. Spatial Information Research, 2023. Vol. 31. No. 1. DOI: 10.1007/s41324-023-00509-1.
15. Rathore S et al. Simulation of Land Use and Land Cover Using the MOLUSCE Plugin Integrated with QGIS for the Western Himalayan Region of India // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2025. Vol. XLVIII-M-5-2024. P. 81–86.

16. Gunduz H. I. Land-Use Land-Cover Dynamics and Future Projections Using GEE, ML, and QGIS-MOLUSCE: A Case Study in Manisa. *Sustainability*, 2025. Vol. 17. No. 4. P. 1363. DOI: 10.3390/su17041363.
17. Jodhani K. H. et al. ML-Based Land Use and Land Cover Classification: Assessing Performance and Predicting Future Changes. *Journal of Hydrologic Engineering*, 2025. Vol. 30. No. 4.
18. Kazakov E., Novikov A. Land Cover Dynamics Simulations with MOLUSCE Plugin in QGIS // FOSS4G Europe 2025 Workshops.
19. Свободные земли в Красноярском крае: на 1 января 2025 года площадь составила 4962,41 га // Росреестр Красноярского края, 2025.
20. Khan D., Khan N., Choudhury U., Singh S. K., Kanga S., Kumar P., Meraj G. Urban Expansion and Spatial Growth Patterns in Lucknow: Implications for Sustainable Development (1991–2021). *Sustainability*, 2025. Vol. 17. No. 1. P. 227. DOI: 10.3390/su17010227.
21. Habibie M. I., Nurda N., Fernando D., Arifandri R., Putra P. K., Prayogi H., Sencaki D. B. Integrating Sentinel-2 and ESA world cover for effective land use and land cover assessment using machine learning. *Advances in Space Research*, 2025. Vol. 76. Iss. 9. P. 4925–4958.

Literature

1. Yakimov A. S., Gavrilov A. V., Kondratiev A. S. Assessment of vegetation cover transformation in the area of the Olympiadinsky Mining and Processing Plant (MPP) using spectral indices (2000–2023). *Geoecology. Engineering Geology. Hydrogeology. Geocryology*, 2024. No. 3. P. 45–57.
2. Shpedt A. A., Edimeichev Yu. F., Trubnikov Yu. N. Agroecological aspects of designing adaptive landscape farming systems in conditions of Central Siberia. *Achievements of Science and Technology of Agro-Industrial Complex*, 2018. Vol. 32. No. 5. P. 5–10. DOI: 10.24411/0235-2451-2018-10501.
3. Antamoshkina O. A., Korets M. A., Ryzhkova V. A., Danilova I. V. Land cover dynamics in the region of ZOTTO observatory (central Siberia) for 2000–2014

- according to Landsat data. *Journal of Siberian Federal University. Biology*, 2016. Vol. 9. No. 4. P. 428–442.
4. Syroezhko E. V., Ponomarev E. I. Assessment of technogenic landscape transformation in the permafrost zone of the Norilsk industrial region based on Landsat-8 and Landsat-9 data. *Current Problems in Remote Sensing of the Earth from Space*, 2024. Vol. 21. No. 2. P. 115–129.
 5. Ponomareva T. V., Shpedt A. A., Edimeichev Yu. F. Post-agrogenic evolution of soils in the Krasnoyarsk forest-steppe based on remote sensing data. *Eurasian Soil Science*, 2015. No. 8. P. 915–925.
 6. Report on the condition and use of lands in Krasnoyarsk Krai in 2024. Krasnoyarsk: Rosreestr Office for Krasnoyarsk Krai, 2025. 87 p.
 7. The area of free land in Krasnoyarsk Krai intended for housing construction is 4962.4094 hectares. KartGeocentre, 2025. January 24. URL: <https://kartgeocentre.ru/polezno-znat/ploshchad-svobodnyh-zemel-v-krasnoyarskom-krae-prednaznachennyh-dlya-zhilishchnogo> (accessed 08.04.2026).
 8. Voloshin N. Yu. Factor analysis of the urban environment of Krasnoyarsk. *Bulletin of Science*, 2025. Vol. 2. No. 6. P. 1155–1163.
 9. NextGIS. MOLUSCE Documentation. Version 4.0. URL: https://docs.nextgis.com/docs_ngqgis/source/molusce.html (accessed 08.04.2026).
 10. MOLUSCE — Modules for Land Use Change Simulations. QGIS Plugins Repository. URL: <https://plugins.qgis.org/plugins/molusce/> (accessed 08.04.2026).
 11. NextGIS. MOLUSCE 4.0: Analyze and predict land use dynamics in QGIS. 2024. September 10. URL: <https://nextgis.ru/molusce-4-0/> (accessed 08.04.2026).
 12. Landis J. R., Koch G. G. The measurement of observer agreement for categorical data. *Biometrics*, 1977. Vol. 33. No. 1. P. 159–174.

13. The parliament discussed the effective use of agricultural land. Krasnoyarsk News, 2025. May 16. URL: <https://krasnoyarsk-news.ru> (accessed 08.04.2026).
14. Amgoth A., Rani H. P., Jayakumar K. V. Exploring LULC changes in Pakhal Lake area, Telangana, India using QGIS MOLUSCE plugin. *Spatial Information Research*, 2023. Vol. 31. No. 1. DOI: 10.1007/s41324-023-00509-1.
15. Rathore S. et al. Simulation of Land Use and Land Cover Using the MOLUSCE Plugin Integrated with QGIS for the Western Himalayan Region of India. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2025. Vol. XLVIII-M-5-2024. P. 81–86.
16. Gunduz H. I. Land-Use Land-Cover Dynamics and Future Projections Using GEE, ML, and QGIS-MOLUSCE: A Case Study in Manisa. *Sustainability*, 2025. Vol. 17. No. 4. P. 1363. DOI: 10.3390/su17041363.
17. Jodhani K. H. et al. ML-Based Land Use and Land Cover Classification: Assessing Performance and Predicting Future Changes. *Journal of Hydrologic Engineering*, 2025. Vol. 30. No. 4.
18. Kazakov E., Novikov A. Land Cover Dynamics Simulations with MOLUSCE Plugin in QGIS. *FOSS4G Europe 2025 Workshops*, 2025.
19. Free lands in Krasnoyarsk Krai: as of January 1, 2025, the area amounted to 4962.41 hectares. Rosreestr Office for Krasnoyarsk Krai, 2025.
20. Khan D., Khan N., Choudhury U., Singh S. K., Kanga S., Kumar P., Meraj G. Urban Expansion and Spatial Growth Patterns in Lucknow: Implications for Sustainable Development (1991–2021). *Sustainability*, 2025. Vol. 17. No. 1. P. 227. DOI: 10.3390/su17010227.
21. Habibie M. I., Nurda N., Fernando D., Arifandri R., Putra P. K., Prayogi H., Sencaki D. B. Integrating Sentinel-2 and ESA world cover for effective land use and land cover assessment using machine learning. *Advances in Space Research*, 2025. Vol. 76. Iss. 9. P. 4925–4958.