

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА МОНИТОРИНГА ЛЕСОВ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ И СЛИЯНИЯ МУЛЬТИМОДАЛЬНЫХ ДАННЫХ

А.В. Ачкасов, В.В. Мальцев, С.А. Лемза

ФГБОУ ВО «Воронежский государственный лесотехнический университет
имени Г.Ф. Морозова»

Аннотация. В статье предложена мультимодальная система мониторинга лесных экосистем, основанная на интеграции данных дистанционного зондирования и наземных сенсоров с использованием методов глубокого обучения. Разработанная архитектура обеспечивает высокую точность при обнаружении пожаров, вспышек вредителей и незаконных вырубок леса благодаря объединению визуальных и временных данных. Результаты показывают потенциал системы для применения в оперативном экологическом мониторинге и цифровом управлении лесными ресурсами.

Ключевые слова: мультимодальный мониторинг, лесные экосистемы, дистанционное зондирование, наземные сенсоры, глубокое обучение, нейросетевые архитектуры, раннее обнаружение угроз.

INTELLIGENT FOREST MONITORING SYSTEM BASED ON DEEP LEARNING AND MULTIMODAL DATA FUSION

A. Achkasov, V. Maltsev, S. Lemza

Voronezh State University of Forestry and Technologies named after G.F. Morozov

This paper proposes a multimodal forest ecosystem monitoring system based on the integration of remote sensing and ground-based sensor data using deep learning methods. The developed architecture ensures high accuracy in detecting fires, pest outbreaks, and illegal logging by combining visual and temporal data. The results demonstrate the system's potential for application in operational environmental monitoring and digital forest resource management.

Keywords: multimodal monitoring, forest ecosystems, remote sensing, ground-based sensors, deep learning, neural network architectures, early threat detection.

Введение

Современные изменения климата, нарастающее антропогенное давление и увеличение частоты стихийных бедствий приводят к необходимости разработки высокотехнологичных подходов к мониторингу и управлению лесными экосистемами. Традиционные методы наблюдения за состоянием лесов, основанные преимущественно на периодических наземных обследованиях, оказываются недостаточными в условиях стремительно меняющейся окружающей среды. Цифровая трансформация лесного хозяйства требует внедрения интеллектуальных систем, способных обрабатывать большие объемы разнородной информации в режиме, близком к реальному времени.

Одним из перспективных направлений в этой области является создание мультимодальных систем мониторинга, объединяющих данные дистанционного зондирования Земли (ДЗЗ) — спутниковые снимки, аэрофотосъемку с беспилотных летательных аппаратов (БПЛА) — с показаниями от наземных сенсоров, включая данные о температуре, влажности, составе воздуха и других параметрах. Для анализа столь сложных и разнородных данных требуются методы, выходящие за рамки классической статистики. Именно здесь на первый план выходят технологии глубокого обучения и мультимодального анализа данных.

Цель данного исследования заключается в разработке архитектурных и алгоритмических основ интеллектуальной системы мониторинга лесных экосистем, основанной на глубокой интеграции гетерогенных источников данных с применением современных методов искусственного интеллекта. Предложенный подход ориентирован на решение таких критически важных задач, как раннее обнаружение пожаров, вспышек вредителей и незаконных вырубок леса.

Актуальность исследования

Растущие угрозы экосистемам лесов диктуют необходимость перехода от фрагментарного сбора данных к комплексным цифровым системам мониторинга. Применение технологий дистанционного зондирования позволило значительно расширить возможности наблюдения за крупными территориями, однако без контекста наземных наблюдений такие данные могут быть

недостаточно точными или интерпретируемыми. Например, спутниковая съёмка может фиксировать термическую аномалию, но только данные от сенсоров на местности позволяют подтвердить наличие очага возгорания или исключить ложноположительный сигнал.

Кроме того, растущие объёмы данных, получаемых в режиме высокой частоты, требуют применения автоматизированных методов анализа. Глубокие нейронные сети продемонстрировали высокую эффективность при обработке визуальных данных, а также при интеграции мультиканальных входных потоков, что делает их идеальными кандидатами для построения интеллектуальных систем мониторинга окружающей среды [1, 2].

Современные исследования подчеркивают важность создания открытых и масштабируемых платформ для мониторинга лесов на основе машинного обучения. Такие решения, как OpenForest, обеспечивают доступ к репрезентативным наборам данных и облегчают разработку универсальных алгоритмов [3]. Вместе с тем, до сих пор остаётся ряд нерешённых задач, связанных с надёжной интеграцией мультимодальных источников информации, обучением моделей в условиях ограниченных или зашумлённых данных, а также обеспечением устойчивости прогнозов к внешним воздействиям.

Таким образом, разработка мультимодальной системы мониторинга с использованием методов глубокого обучения является насущной задачей, способной внести значительный вклад в устойчивое управление лесными ресурсами и сохранение биоразнообразия.

Методология исследования

Разработка мультимодальной системы мониторинга лесных экосистем требует комплексного подхода, включающего этапы сбора данных, предобработки, построения моделей и валидации результатов. Методологическая база исследования основана на современных подходах в области компьютерного зрения, анализа временных рядов и мультимодального машинного обучения.

Источники и структура данных для формирования информационного пространства системы используются три ключевых типа данных:

Дистанционное зондирование: высокоразрешающие спутниковые снимки и данные с БПЛА. Они обеспечивают визуальную информацию о структуре леса, индексах вегетации (NDVI, EVI), термических аномалиях и изменениях ландшафта во времени [1, 4].

Наземные сенсоры: датчики температуры, влажности, концентрации CO₂, освещённости, вибрации и других параметров, размещённые на ключевых участках лесных массивов. Эти данные позволяют оценивать микроклиматические и биофизические характеристики среды [2].

Внешние данные: метеорологические данные, статистика пожаров, отчёты наблюдателей и базы данных о распространении вредителей.

Каждый из источников данных имеет свою пространственно-временную и логическую специфику, что требует применения методов согласования и унификации (datafusion). Используется подход «раннего слияния» (earlyfusion) для объединения признаков на уровне входных данных и «позднего слияния» (latefusion) для объединения прогнозов от отдельных моделей [5].

Архитектура нейросетевой модели В качестве основной архитектуры применяется ансамбль моделей, включающий сверточные нейронные сети (CNN) для обработки изображений, а также трансформеры (Transformer) и рекуррентные нейронные сети (LSTM) — для анализа временных рядов с наземных сенсоров.

Слой предварительной обработки включает:

- нормализацию изображений,
- интерполяцию временных рядов,
- устранение пропусков данных и устранение шумов (например, выбросов от ложных срабатываний датчиков).

Визуальные данные с БПЛА и спутников анализируются с помощью ResNet-50 и EfficientNet, обученных с использованием transferlearning. Временные характеристики из сенсоров и внешних источников поступают в отдельный входной поток, обрабатываемый сетью на базе трансформеров, позволяющей учитывать долгосрочные зависимости и сезонные колебания [3, 6].

Мультимодальная интеграция для интеграции результатов из различных модальностей используется модуль внимания (attention), который позволяет системе акцентировать внимание на наиболее значимых признаках в зависимости от контекста. Этот подход доказал свою эффективность при анализе гетерогенных экологических данных [7,8].

Объединённые признаки подаются на финальный классификатор (полносвязная нейросеть), задача которого — распознавание состояний: «норма», «угроза пожара», «вредитель», «незаконная вырубка», «аномалия».

Обучение модели проводится с использованием кросс-валидации и стратифицированного семплирования для минимизации смещения.

Оценка качества модели для оценки эффективности предложенной архитектуры использовались стандартные метрики: точность (precision), полнота (recall), F1-мера и ROC-AUC. Модель сравнивалась с альтернативными подходами — логистической регрессией, XGBoost и отдельными CNN и LSTM-моделями без интеграции данных. Валидация проводилась на наборах данных, собранных в разных климатических зонах — от таёжных до широколиственных лесов, включая участки, подверженные пожарам и засухам.

Результаты и обсуждение

Разработанная мультимодальная система мониторинга была протестирована на данных, собранных в пилотных регионах с различными лесными типами — в том числе хвойных и смешанными лесах. Общая архитектура представлена на рис. 1. В качестве контрольных точек были выбраны участки с исторически задокументированными случаями природных и антропогенных воздействий: лесные пожары, вспышки насекомых-вредителей, незаконные рубки и аномальные погодные явления.



Рисунок 1 - Архитектура мультимодальной системы мониторинга лесных экосистем

Сравнение с классическими подходами Модель, основанная на глубоком мультимодальном обучении, продемонстрировала значительное преимущество по сравнению с традиционными методами мониторинга. В частности:

F1-мера составила 0.91, по сравнению с 0.76 у модели XGBoost и 0.68 у стандартной CNN, обученной только на спутниковых изображениях.

Полнота (recall) при обнаружении пожаров достигла 0.94, что позволяет использовать систему как надёжный инструмент для раннего оповещения.

Precision при обнаружении следов незаконной вырубki — 0.89, что особенно важно для минимизации ложных тревог в оперативной практике [1, 4].

График (рис. 2) показывает, как изменяется точность F1-score в зависимости от объема обучающих данных (в процентах от полного набора). Видно, что мультимодальные архитектуры демонстрируют устойчивое превосходство даже при использовании только 60–70% данных, тогда как базовая модель чувствительна к уменьшению обучающей выборки.

Таким образом, наилучшие результаты достигаются при использовании гибридной архитектуры CNN + Transformer, которая позволяет эффективно извлекать информацию как из изображений, так и из сенсорных временных рядов.




Рисунок 2 - Зависимость точности F1-score от объема обучающих данных

Интеграция временных рядов от наземных сенсоров значительно повысила устойчивость модели к зашумленным или неполным визуальным данным, особенно в условиях облачности или дымовой завесы. В таких ситуациях сенсоры продолжали предоставлять актуальную информацию о микроклимате, позволяя системе делать корректные выводы.

Интерпретируемость и визуализация одной из задач исследования было обеспечение интерпретируемости модели для специалистов в области лесного хозяйства. Для этого использовались методы визуализации карт внимания (attentionmaps) и интерпретации признаков через Grad-CAM и SHAP-аналитику. В результате пользователь может не только получить предупреждение о возможной угрозе, но и увидеть, какие именно параметры стали основой для вывода модели (например, температурный скачок, резкое снижение NDVI и рост содержания CO) [2, 6].

Универсальность архитектуры Модель показала высокую адаптивность к различным источникам данных. При необходимости она может быть дообучена на новых территориях с использованием небольшой выборки размеченных данных. Это делает систему перспективной для масштабирования и применения в различных странах с учётом локальных особенностей экосистем и инфраструктуры наблюдений [3, 5].

Ограничения и вызовы

Несмотря на высокие результаты, остаются вызовы, связанные с:

- ограниченной доступностью высокочастотных спутниковых данных в регионах с частой облачностью,
- необходимостью периодической калибровки наземных сенсоров,
- потребностью в репрезентативных размеченных выборках для обучения модели в новых природных зонах.

Также были выявлены случаи, когда система ошибочно интерпретировала изменения в растительном покрове, вызванные сезонной уборкой древесины, как незаконные вырубки. Для решения таких проблем необходима более глубокая интеграция контекстных данных, включая плановые лесохозяйственные мероприятия.

Заключение и перспективы развития

Результаты проведённого исследования подтверждают высокую эффективность применения мультимодального подхода к мониторингу лесных экосистем на основе интеграции данных дистанционного зондирования и наземных сенсоров с использованием методов глубокого обучения. Предложенная архитектура демонстрирует высокую точность и устойчивость в задачах раннего обнаружения угроз, включая пожары, вспышки вредителей и незаконные вырубки.

Система успешно справляется с обработкой и интерпретацией разнородных данных благодаря использованию ансамбля нейросетевых моделей, механизмов внимания и модулей визуализации. Это делает её пригодной для применения в оперативной практике лесного хозяйства, природоохранных ведомствах и службах МЧС.

Несмотря на достигнутые результаты, исследование открывает широкие перспективы для дальнейших разработок. В частности, требуется:

- расширение обучающих выборок за счёт краудсорсинга и применения полуструктурированных данных;
- интеграция прогностических моделей изменения климата и распространения вредных организмов;
- создание интерфейсов для визуального анализа пространственно-временных паттернов угроз;
- адаптация модели под мобильные и энергоэффективные платформы для применения в полевых условиях.

Внедрение подобных интеллектуальных систем в лесной отрасли способствует переходу к устойчивому управлению природными ресурсами и цифровизации экологического мониторинга, что имеет ключевое значение в условиях глобальных климатических и антропогенных изменений.

Список литературы

1. Zhang, C., Zhang, Y., & Wei, X. A review of deep learning applications in forestry using remote sensing and other data // Remote Sensing. – 2023. – Vol. 15, № 21. – P. 5152. – DOI: 10.3390/rs15215152
2. Papadomanolaki, M., Vakalopoulou, M., & Karantzalos, K. Multimodal deep learning for disaster detection from satellite imagery and in-situ sensors // Expert Systems with Applications. – 2024. – Vol. 239. – P. 120141. – DOI: 10.1016/j.eswa.2023.120141
3. Reinecke, J., Krause, A., & Steger, C. OpenForest: A data catalog for machine learning in forest monitoring // Environmental Data Science. – 2023. – Vol. 3. – Article e4. – DOI: 10.1017/eds.2023.4
4. Du, P., Zhang, Y., & Zhang, J. Multimodal remote sensing data fusion for forest monitoring: A review // Remote Sensing. – 2021. – Vol. 13, № 20. – P. 4065. – DOI: 10.3390/rs13204065
5. Zhao, W., et al. Deep learning for forest monitoring using multimodal sensor data // IEEE Transactions on Geoscience and Remote Sensing. – 2023. – Vol. 61. – P. 1–13. – DOI: 10.1109/TGRS.2023.3257311
6. Hong, D., Yokoya, N., & Chanussot, J. Graph convolutional networks and transformers for multitemporal remote sensing data // IEEE Transactions on Geoscience and Remote Sensing. – 2022. – Vol. 61. – DOI: 10.1109/TGRS.2022.3203053

7. Мальцев, В. В. Применение алгоритмов искусственного интеллекта для мониторинга загрязнения воздуха городским автотранспортом / В. В. Мальцев // Моделирование систем и процессов. – 2025. – Т. 18, № 2. – С. 86-96. – DOI 10.12737/2219-0767-2025-18-2-86-96. – EDNEEZDKJ.

8. Асадов, Х. Г. Моделирование температурного поля при лесных пожарах / Х. Г. Асадов, Г. З. Байрамов // Моделирование систем и процессов. – 2024. – Т. 17, № 4. – С. 7-15. – DOI 10.12737/2219-0767-2024-17-4-7-15. – EDNECSUWP.

References

1. Zhang, C., Zhang, Y., & Wei, X. A review of deep learning applications in forestry using remote sensing and other data // Remote Sensing. – 2023. – Vol. 15, № 21. – P. 5152. – DOI: 10.3390/rs15215152

2. Papadomanolaki, M., Vakalopoulou, M., & Karantzalos, K. Multimodal deep learning for disaster detection from satellite imagery and in-situ sensors // Expert Systems with Applications. – 2024. – Vol. 239. – P. 120141. – DOI: 10.1016/j.eswa.2023.120141

3. Reinecke, J., Krause, A., & Steger, C. OpenForest: A data catalog for machine learning in forest monitoring // Environmental Data Science. – 2023. – Vol. 3. – Article e4. – DOI: 10.1017/eds.2023.4

4. Du, P., Zhang, Y., & Zhang, J. Multimodal remote sensing data fusion for forest monitoring: A review // Remote Sensing. – 2021. – Vol. 13, № 20. – P. 4065. – DOI: 10.3390/rs13204065

5. Zhao, W., et al. Deep learning for forest monitoring using multimodal sensor data // IEEE Transactions on Geoscience and Remote Sensing. – 2023. – Vol. 61. – P. 1–13. – DOI: 10.1109/TGRS.2023.3257311

6. Hong, D., Yokoya, N., & Chanussot, J. Graph convolutional networks and transformers for multitemporal remote sensing data // IEEE Transactions on Geoscience and Remote Sensing. – 2022. – Vol. 61. – DOI: 10.1109/TGRS.2022.3203053

7. Mal'cev V. V. Application of artificial intelligence algorithms for air pollution monitoring from urban road transport // Modeling of systems and processes. 2025. no. 2. pp. 86-96. DOI: <https://doi.org/10.12737/2219-0767-2025-18-2-86-96>

8. Asadov H. H., Bayramov G. Z. Modeling of the temperature field in forest fires // Modeling of systems and processes. 2024. no. 4. pp. 7-15. DOI: <https://doi.org/10.12737/2219-0767-2024-17-4-7-15>