

УДК 528.91:630

DOI: 10.33764/2411-1759-2020-25-3-201-213

## СОВРЕМЕННЫЕ МЕТОДЫ ОПЕРАТИВНОГО КАРТОГРАФИРОВАНИЯ НАРУШЕНИЙ ЛЕСНОГО ПОКРОВА

*Андрей Владимирович Тарасов*

Пермский государственный национально-исследовательский университет, 614990, Россия, г. Пермь, ул. Букирева, 15, аспирант кафедры картографии и геоинформатики, e-mail: andrew.tarasov1993.study@gmail.com

Своевременное и оперативное выявление нарушений в лесном фонде – важная задача при ведении лесохозяйственной деятельности в РФ. Раннее выявление участков насаждений, поврежденных в результате воздействия природных или антропогенных факторов, позволяет оперативно принимать управленческие решения. Для реализации такой стратегии управления необходимо использовать методы оперативного картографирования. С появлением данных дистанционного зондирования Земли (ДДЗЗ), которые обладают высоким пространственным и временным разрешением (Planet, Sentinel-2), становится возможным использовать современные методы оперативного картографирования для решения задач лесного хозяйства (в частности, выявление нарушений лесного покрова). По мере увеличения площади мониторинга и роста количества снимков возрастает необходимость в автоматизации этого процесса. В данной статье представлено описание «традиционных» методов выявления нарушений лесного покрова (вегетационные индексы, преобразование Tasseled Cap, многоканальное и одноканальное обнаружение изменений и др.), их основные принципы, ограничения, опыт применения в России и в мире. В качестве альтернативны представлены алгоритмы, основанные на методах машинного обучения, представлена их классификация. Отмечены преимущества и недостатки двух групп методов выявления нарушений лесного покрова. Обозначено, что опыт применения методов машинного обучения для обработки ДДЗЗ небольшой, а подобные исследования обладают высоким уровнем новизны.

**Ключевые слова:** оперативное картографирование, методы обработки данных дистанционного зондирования земли, PlanetScope, Sentinel-2, машинное обучение.

### *Введение*

Понятие «оперативное картографирование» подразумевает под собой создание и использование карт в реальном или близком к реальному масштабу времени с целью своевременного информирования пользователей для возможного воздействия на ход процесса. При этом реальный масштаб времени понимается как характеристика скорости создания и использования карт, т. е. темпа, обеспечивающего немедленную обработку поступающей информации, ее картографическую визуализацию для оценки, мониторинга, управления, контроля каких-либо процессов и явлений, изменяющихся в том же темпе [1].

В России теория оперативного картографирования разрабатывается с 90-х гг. XX в. Оперативно-хозяйственные карты впервые выделены в классификации карт, предложенной в работе [2]. А. М. Берлянт предло-

жил классификацию карт по оперативности, он выделяет два типа карт: оперативные и базовые [1]. Реализация методов оперативного картографирования на практике стала возможна по мере развития ГИС-технологий и регулярно обновляемых источников пространственных данных, в том числе данных дистанционного зондирования Земли. В настоящее время оперативное картографирование стало одним из направлений геоинформационного картографирования. В современных условиях с появлением новых спутников, которые обладают высоким пространственным и временным разрешением (PlanetScope, Sentinel-2) возможна реализация оперативного картографирования в новых областях, в которых до недавнего времени это было невозможно по причине отсутствия необходимых данных. К таким областям относится лесное хозяйство и, в частности, мониторинг нарушений лесного покрова.

В Российской Федерации ежегодные потери леса в результате действия антропогенных и природных факторов составляют в среднем несколько миллионов гектаров, а в отдельные годы свыше 10 млн га [3, 4]. В связи с этим является актуальным вопрос своевременного и эффективного способа выявления нарушений лесного покрова. Нарушения лесного покрова традиционно классифицируют на природные (в англоязычной терминологии – natural forest disturbances) и антропогенные (human-induced disturbances). В свою очередь, природные нарушения могут быть вызваны абиотическими и биотическими факторами. Среди первых наиболее значимыми являются лесные пожары, засухи и ветровалы, а среди вторых – повреждения, вызванные насекомыми-вредителями, а также болезни леса [5]. Приведенная классификация с некоторыми изменениями используется в большинстве исследований по оценке различных факторов, вызывающих нарушения лесного покрова.

Также широко используется классификация нарушений лесного покрова по характеру повреждения лесов. Выделяются сплошные нарушения (резкая гибель насаждений на значительной площади), а также несплошные (мозаичные) нарушения с разной степенью повреждения древостоя. В англоязычной литературе им соответствуют понятия stand-replacing disturbances и non-stand replacing disturbances [3]. Характер повреждения древостоя имеет решающее влияние на выбор ДДЗЗ, используемых для организации мониторинга, а также на возможность автоматизации распознавания нарушений по снимкам [6].

Вклад различных типов нарушений в общую площадь потерь лесного покрова существенно различается для разных регионов России и мира. Так, по данным [3], в целом по России за 2002–2011 гг. 65,5 % площади потерь лесного покрова были вызваны пожарами, а около 30 % связаны с лесозаготовкой. При этом средняя площадь лесозаготовок оценивалась в 0,8 млн га/год. На другие нарушения приходится всего 4,5 % площади потерь лесов. В Восточной Европе, включая также Европейскую территорию России,

вклад естественных нарушений составляет меньше 10 % от общей площади потерь лесов [7]. Лишь в отдельные годы он может достигать 30–50 %, главным образом за счет крупных лесных пожаров.

### ***«Традиционные» методы выявления нарушений лесного покрова по спутниковым данным***

Нарушения лесного покрова имеют свой набор дешифровочных признаков, который позволяет выделять их на космических снимках. К ним относятся спектральный образ, форма, площадь, внутренняя структура и текстура. По мере роста площади мониторинга и количества снимков возникает необходимость автоматизировать этот процесс. Методы автоматизации выявления нарушений на основе этих признаков разрабатываются на протяжении нескольких десятилетий, практически с момента запуска первых спутников серии Landsat и появления первых цифровых снимков Земли из космоса. Так, еще в работе [8] было предложено использовать мультивременные синтезы из различных каналов съемочной системы MSS/Landsat для идентификации участков гибели (дефолиации) лесов в результате вспышек насекомых-вредителей. В исследовании [9] впервые применены снимки Landsat для определения площади гибели лесов, вызванной пожарами и ветровалами.

С запуском в 1984 г. спутника Landsat-4 с сенсором ТМ (6 спектральных каналов с пространственным разрешением 30 м) возможности космического мониторинга лесов по разновременным снимкам значительно расширились. При повреждении растений и снижении фотосинтеза отражение в красной области спектра увеличивается, а в ближней – инфракрасной (ИК) падает, а также значительно возрастает отражательная способность в среднем ИК-канале, что связано с падением содержания влаги в поврежденных деревьях. На этих свойствах основаны разнообразные вегетационные индексы, используемые для выявления нарушений лесного покрова. Наиболее известными из них являются нормализованный разностный ве-

гетационный индекс NDVI, нормализованный индекс инфракрасной разности NDII (в русскоязычной литературе он же – коротковолновой вегетационный индекс SWVI) и нормализованный разностный индекс гарей NBR. Идентификация нарушений лесного покрова производится по разности этих индексов, вычисленной по разновременным снимкам.

В дальнейшем была показана высокая эффективность индекса NDII для выявления вырубок, ветровалов и участков повреждения лесов вредителями [10–12]. В этих же работах подтверждено, что индекс NDII более эффективен для выявления нарушений лесного покрова, чем широко известный NDVI. В свою очередь разностный индекс NBR весьма эффективен для выявления выгоревших территорий и имеет высокую корреляцию со степенью повреждения лесов пожарами [13].

Для обнаружения нарушений лесного покрова в ряде работ рассматривалось применение более сложных индексов, чем простые нормализованные разности. К ним относятся как индексы, основанные на видимом и ближнем ИК-диапазонах спектра (SAVI и др.), так и с использованием среднего ИК-диапазона, а также результаты преобразования Tasseled Cap [14]. Преобразование Tasseled Cap – частный случай анализа главных компонент. В исследовании [15] провели сравнительный анализ эффективности различных вегетационных индексов и ряда других методов обнаружения изменений по снимкам Landsat на примере ущерба от урагана Катрина в США и установили, что наибольшую точность обеспечивает именно это преобразование (Tasseled Cap). В этом преобразовании используются 6 каналов съемочной системы TM/Landsat с разными весами, причем максимальный вес имеет средний ИК-канал.

Помимо вегетационных индексов, для картографирования нарушений лесного покрова по снимкам оптического диапазона успешно применяется ряд других методов: одномерное и многомерное обнаружение изменений, анализ векторов изменений, сравнение результатов классификации, деревья решений.

Метод многомерного обнаружения изменений (Multivariate alteration detection, MAD)

основан на построении многомерной корреляции между снимками (каноническом корреляционном анализе). Его преимуществом является сниженная чувствительность к настройкам сенсора, а также схемам радиометрической и атмосферной коррекции [16]. Метод MAD реализован в программном пакете Scanex Image Processor, разработанном ИТЦ СканЭкс, а в Руководстве пользователя [17] приведено его описание.

Выборочный анализ главных компонент (selective PCA) основан на использовании двух входных переменных – по одному каналу снимков, полученных до и после события, или их производных (NDVI или результатов преобразования Tasseled Cap) [18].

Метод анализа векторов изменений (change vector analysis, CVA), предложенный в работе [19], позволяет определить две компоненты изменений – магнитуду и направление. Он обеспечивает, во-первых, разделение реально произошедших изменений на местности и фоновых (связанных, например, с появлением атмосферной дымки), а также в ряде случаев определение характера изменений (положительные/отрицательные изменения и их возможная причина), что не позволяет определить метод MAD.

Сравнение результатов классификации разновременных снимков (post-classification comparison, PCC) также может использоваться для выявления нарушений лесного покрова с высокой точностью [15]. Недостатком данного метода является низкая степень автоматизации и сложность настройки параметров классификатора для множества снимков.

Современным и эффективным методом обнаружения изменений лесного покрова является построение «деревьев решений» (decision tree). Именно построение дерева решений на основе многолетнего ряда снимков Landsat, полученных за вегетационный период, было использовано в проекте Global Forest Change для создания ежегодно обновляемых данных о нарушениях лесного покрова Земли. Для лесов умеренной зоны данные о площади потерь имеют точность свыше 90 % [20].

В России разработку методов обнаружения нарушений лесного покрова длительное

время ведут Институт космических исследований (ИКИ) РАН и Российский центр защиты леса. В ИКИ РАН до недавнего времени основное внимание уделялось оценке повреждения лесов пожарами, для чего также успешно применяются разностные и относительные индексы, основанные на среднем ИК-диапазоне спектра [21]. Обзор российского опыта мониторинга нарушений лесного покрова и существующих проблем в данной области приведен в работе [11]. Также в данной работе предложены методические рекомендации и представлены результаты мониторинга ветровалов в лесах Европейской части России [22] и оценки повреждения лесов вследствие вспышек размножения вредителей [11]. Большой интерес представляет работа [23], в которой были оценены предельные возможности съемочной системы Landsat для выявления нарушений лесного покрова. Аналогичная методика может быть применена, например, для оценки точности автоматизированного выделения вырубок (в том числе незаконных) по снимкам среднего и высокого разрешения.

Основным ограничением всех перечисленных методов, основанных на спектральных признаках, является невозможность автоматизированного распознавания типов нарушений лесного покрова (вырубки, гари, ветровалы, повреждения вредителями и болезнями). Для решения этой задачи требуется дополнительный анализ геометрических и текстурных признаков, без которого точность разделения будет невысока. Так, в работе [24] была предпринята попытка разделения по спектральным признакам вырубок и ветровалов (на основе преобразования Tasseled Cap и последующей классификации методом опорных векторов). Точность разделения составила 76–77 %, что недостаточно для практического применения. Еще один подобный эксперимент выполнен для разделения всех типов нарушений лесного покрова на территории США с применением современного и эффективного классификатора Random Forest [25]. Однако точность также оказалась невысокой (ошибки до 32 %). Для более точного выделения нарушений необходимо рассматривать не только спектральные

характеристики отдельно, а совместно с текстурой, и, главное, геометрией объекта.

В последние годы возникло еще одно существенное ограничение – новые группировки спутников, обеспечивающие оперативный мониторинг с высокой повторяемостью и детальностью, либо ведут съемку в среднем ИК-канале с более низким пространственным разрешением (Sentinel-2), либо не имеют его вовсе (PlanetScope). Таким образом, алгоритмы обнаружения изменений, разработанные для данных Landsat, часто оказываются неприменимы для данных Sentinel-2 и PlanetScope. Следовательно, требуется разработка новых алгоритмов, использующих данные только видимого и ближнего ИК-диапазона спектра, а также текстурные и геометрические признаки (значимость которых растет с повышением пространственного разрешения данных). Лучше всего для этого подходят методы машинного обучения.

#### ***Современные методы выявления нарушений лесного покрова по спутниковым данным***

Исследования по разработке алгоритмов машинного обучения проводятся уже с середины прошлого века [26]. В 1940–1960-х гг. данное научное направление называлась кибернетикой, затем в 1980–1990-х – коннекционизмом. В современном понимании термин развивается с 2006 г. Именно тогда сформировался термин «Deep learning» (глубокое машинное обучение), который подразумевает использование все более сложных и «глубоких» моделей. [27]. Под «глубиной» в данном случае можно понимать количество слоев, их типы во внутренней структуре и степень связи между ними. Такие модели также отличаются высокой производительностью и возможностью оценки сложных взаимосвязанных факторов. Сам термин «машинное обучение» был определен еще в 1959 г. «как научная дисциплина, которая наделяет компьютеры способностью учиться, не будучи явно запрограммированными» [28], а в 1997 г. было сформулировано более «техническое» определение: «говорят, что

компьютерная программа обучается на основе опыта  $E$  по отношению к некоторой задаче  $T$  и некоторой оценке производительности  $R$ , если ее производительность на  $T$ , измеренная посредством  $R$ , улучшается с опытом  $E$ » [29].

За более чем 50 лет разработки создано множество алгоритмов машинного обучения, но единой общепринятой классификации не существует. Наиболее общая представлена на рис. 1, а более детальный вариант представлен на рис. 2.

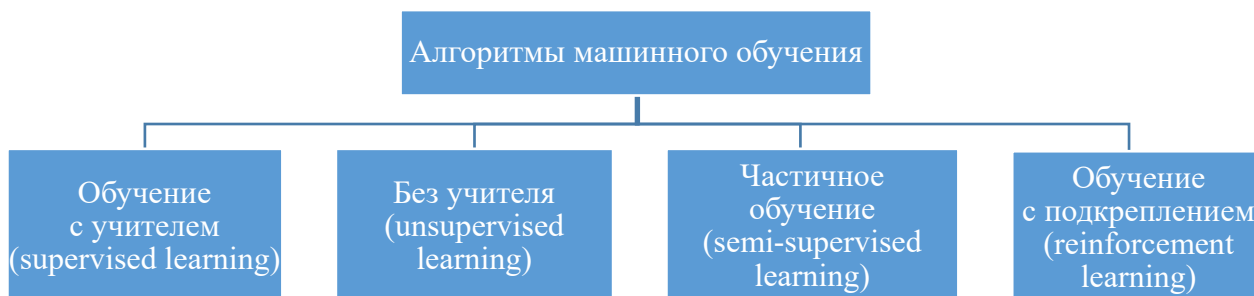


Рис. 1. Базовая классификация алгоритмов машинного обучения

В последние десятилетия наблюдается появление все более сложных архитектур для применения в различных областях, что связано с ростом возможностей вычислительных ресурсов и доступностью наборов для обучения алгоритмов. Методы машинного обучения позволили по-новому подойти к решению классических задач компьютерного зрения: классификации и сегментации изображений. С того момента, как в 2012 г. на соревновании исследователей по разработке алгоритма для распознавания изображений ImageNet Large Scale Visual Recognition Competition (ILSVRC) [30] лучший результат показали исследователи, которые использовали сверточные сети, именно такой тип архитектуры чаще всего используется для обработки изображений.

Обработка ДДЗЗ представляет собой частный случай задачи обработки изображений. Поэтому для их обработки также применяются сверточные нейронные сети. Главное их отличие от традиционных сетей – это наличие сверточных слоев. Принцип работы сверточной сети похож на работу множества последовательных фокальных или скользящих фильтров. Слой нейронной сети, полученный после обработки входного, называется сверточным (convolution layers). На первых слоях выделяются самые простые свойства объекта. С каждым но-

вым уровнем, на основе ранее выделенных признаков, получают признаки объекта более высокого уровня. Наряду со сверточными слоями в сверточных сетях есть полносвязные слои (fully connected layers), слои пуллинга (pooling layers). Первый тип позволяет непосредственно получить результат. Второй тип позволяет сжать входное изображение для сокращения вычислительной нагрузки, расхода памяти и количества параметров, тем самым ограничивая риск переобучения. Можно получить множество различных архитектур, комбинируя различным способом эти слои, меняя порядок, количество слоев и т. п. Существует множество модификаций представленных архитектур (например ResNet50), где исследователи добавляют больше слоев или используют разные параметры при обучении и т. д.

Другой часто используемый для анализа ДДЗЗ алгоритм машинного обучения – RandomForest. Этот алгоритм основан на усреднении значений множества деревьев решений. Деревья решений – простой, но мощный алгоритм машинного обучения. С помощью алгоритмов (например, CART) данные делятся на максимально «чистые» классы. Однородность классов определяется разными метриками (Gini impurity (неоднородность Джини), энтропия).

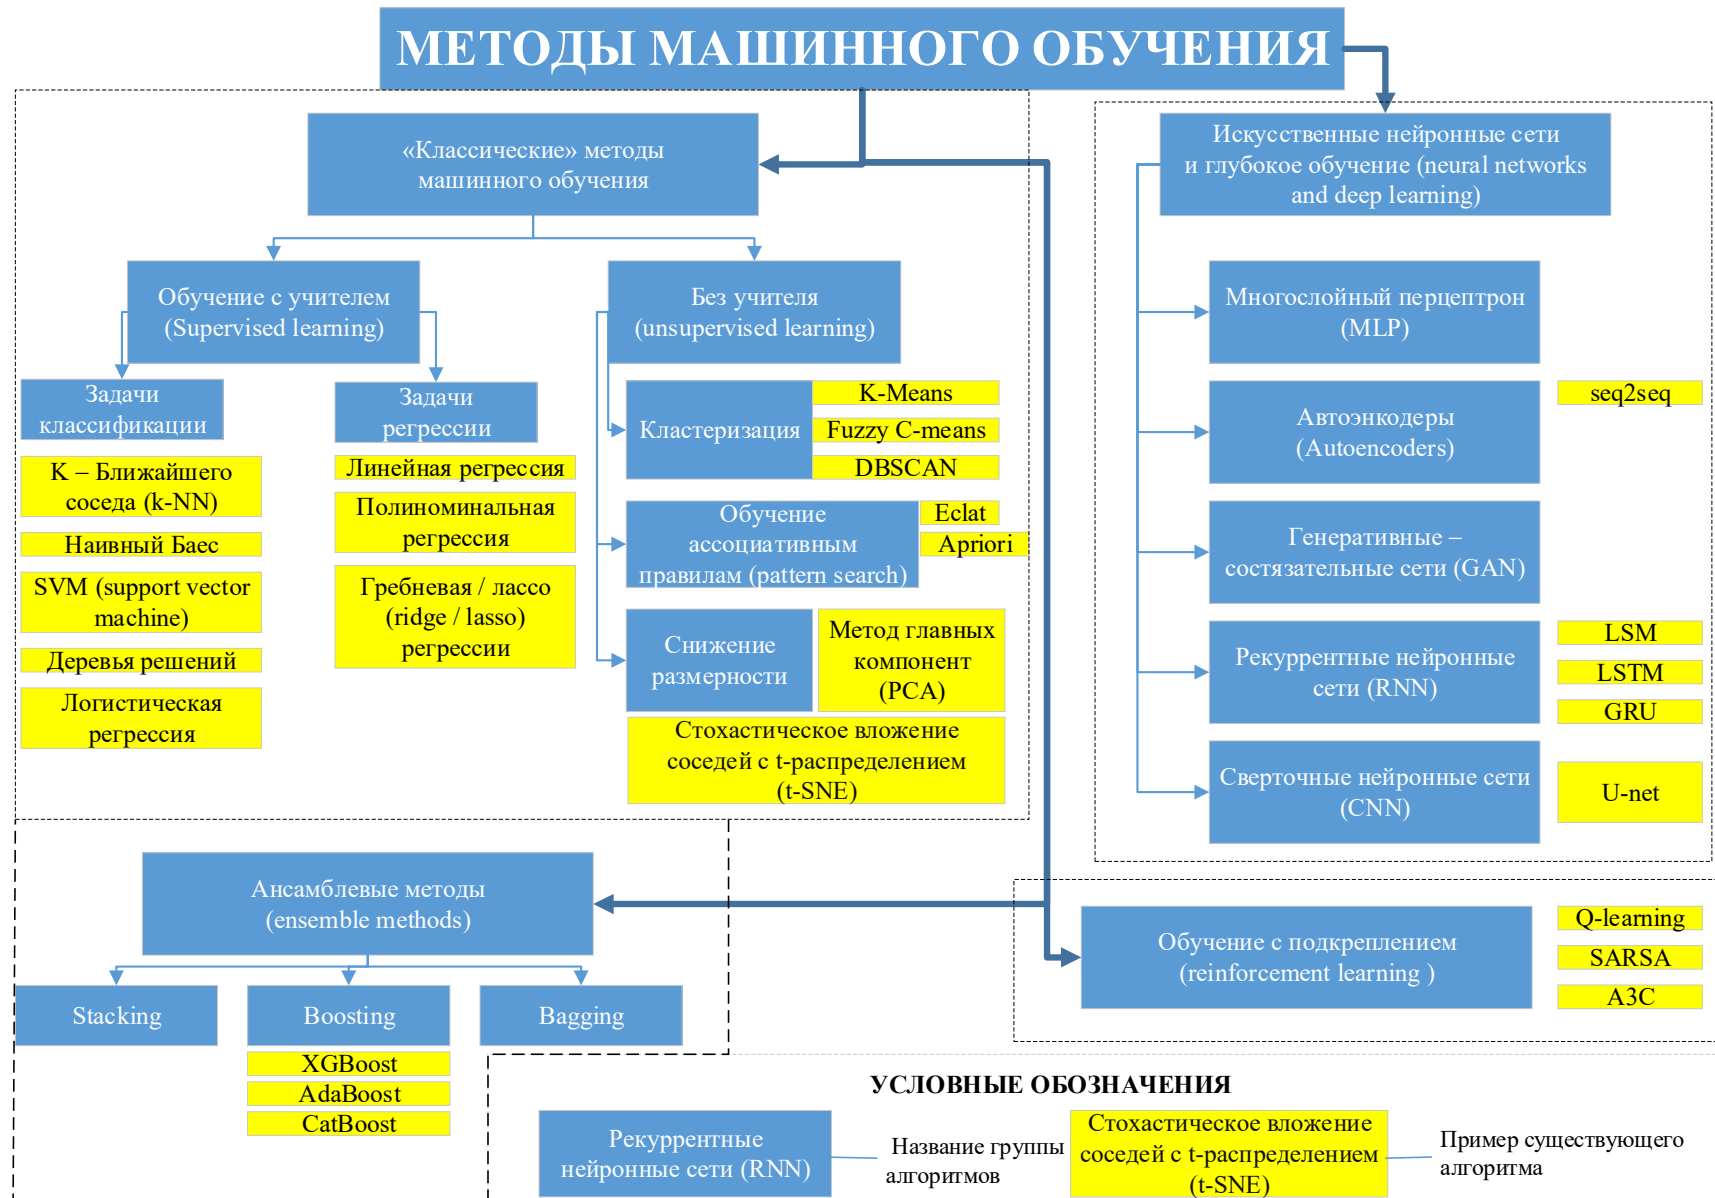


Рис. 2. Расширенная схема классификации методов машинного обучения

Для классификации в каждом конкретном узле используется один признак, а для обучения случайно выбирается поднабор из всего обучающего набора. Именно предсказания множества таких деревьев использует алгоритм Random Forest. Для получения итогового решения учитываются прогнозы всех индивидуальных деревьев и предсказывается класс, который стал обладателем «большинства» голосов [27].

Совместное использование нескольких методов машинного обучения для решения одной задачи называется ансамблевыми методами (ensemble method). К такому типу относятся Random Forest, а также методы бустинга (boosting), стэкинга (stacking), бэггинга (bagging) [27]. Эти методы способны комбинировать нескольких «слабых» учеников в одного «сильного» ученика.

Основная идея большинства методов бустинга предусматривает последовательное обучение нескольких моделей, причем каждая из них старается «исправить» или улучшить своего предшественника. Так повторяется до того момента, пока не получится «идеальная модель» либо закончится число итераций. Результатом в данном случае будет взвешенное значение между прогнозом каждой отдельной модели и ее веса (под весом понимается правильность предсказания в обучающей выборке) (такой алгоритм называется AdaBoosting). Другой вид бустинга – градиентный. Он похож на алгоритм AdaBoosting, только каждая новая модель подгоняется к остаточным ошибкам предыдущего. Прогнозы делаются аналогично предыдущему методу. При бэггинге объединяются несколько моделей, которые обучены на разных поднаборах одной обучающей выборки. Причем одна модель может несколько раз обучаться на разных поднаборах. Итоговый прогноз обычно вырабатывается как статистическая мода (т. е. самый частый прогноз от всех моделей). Метод стэкинга использует еще одну модель (blender, смеситель) для агрегации результатов. Для этого специально выделяется удерживающий (hold-out) набор из обучающей выборки, который не использует ни одна из моделей. Используя результаты отдельных моделей, смеситель предсказывает значения из удерживающего набора [27].

### **Опыт применения методов машинного обучения для мониторинга нарушений лесного покрова**

К настоящему времени опубликовано сравнительно немного работ, где рассматривается применимость алгоритмов обработки изображений, основанных на машинном обучении, для обнаружения нарушений лесного покрова по спутниковым данным. В большинстве случаев алгоритмы сегментации спутниковых снимков средствами глубокого обучения направлены на решение таких задач, как маскирование облачности [31] или классификация типов землепользования [32]. Следовательно, задача обнаружения нарушений лесного покрова с применением этих алгоритмов обладает высоким уровнем новизны.

Из других алгоритмов, основанных на машинном обучении, имеется опыт применения классификатора Random Forest для распознавания выборочных рубок по снимкам Landsat [33]. Точность обнаружения составила около 90 % при этом пропуск объектов – около 8 %, доля ложных срабатываний – 20 %, что можно считать успешным результатом.

В работе [34] рассматриваются возможности картографического сервиса Silvisense [35] для комплексного мониторинга лесов Европы, в том числе обнаружения вырубок, гарей, ветровалов. Отмечается, что для этой задачи используются модели «глубокого обучения» (deep learning), однако оценки точности не приведены.

Еще меньше публикаций посвящено использованию спутниковых данных PlanetScope для решения этих задач. Вероятно, это объясняется тем, что данные появились только в 2017 г. и с 2018 г. распространяются на коммерческой основе. Можно отметить описание технологии мониторинга тропических лесов с высокой периодичностью [36]. Данная технология предполагает выявление нарушений лесного покрова в два этапа: на первом этапе производится семантическая сегментация снимков на несколько классов (лес, водная поверхность, открытая почва, облака и их тени) на основе архитектуры U-net [37] (рис. 3).




Рис. 3. Общая архитектура U-net

На втором этапе анализируется изменение вероятности каждого класса по серии разновременных снимков, в результате чего выявляются участки вырубок и других нарушений лесного покрова.

Решение задачи обработки ДДЗЗ с помощью задач машинного обучения имеет и ограничения. Прежде всего, для создания хорошей модели необходима большая обучающая выборка (dataset, датасет). С увеличением количества образцов все методы машинного обучения будут показывать схожие результаты [38]. Существующие обучающие выборки не всегда подходят для решения новых задач, а создавать новые очень трудозатратно.

Операции обучения модели и дальнейшие предсказания отличаются высокой вычислительной сложностью и требуют наличия соответствующего технического обеспечения. Лучше всего с этими задачами справляются графические процессоры. Обработка ДДЗЗ еще более увеличивает требования к техническим средствам, так как обрабатываемые данные имеют большой объем.

В работе [39] отмечается, что проблемой при обработке спутниковых изображений с помощью нейронных сетей является пространственный экстенд объектов, т. е. их размер. В одном из крупнейших датасетов изображений ImageNet размеченные обучающие объекты имеют большой размер. Та-

ким образом, даже крупные объекты (например, автомобиль) будут занимать только несколько пикселей (в зависимости от пространственного разрешения снимков).

Это ограничения, которые можно преодолеть (например, используя методы бустинга для сокращения размера обучающей выборки). Нейронные сети могут находить структуру в существующих данных и при правильном обучении делать предположения о данных, которые не были использованы в обучении. Нейронные сети – первый алгоритм, который превзошел человека по распознаванию образов [40], поэтому они имеют большой потенциал применения в обработке данных дистанционного зондирования Земли.

Сравнительный анализ описанных методов представлен в таблице.

### Выводы

В настоящее время с появлением новых ДДЗЗ, обладающих высоким пространственным и временным разрешением, появляется возможность использовать методы оперативного картографирования в новых областях (в лесном хозяйстве эта потребность особенно высока). Внедрение систем мониторинга за нарушениями растительного покрова является важной задачей лесопользования.



Сравнение традиционных и современных методов выявления нарушений лесного покрова

Группа методов	Преимущества	Ограничения
«Традиционные» методы выявления нарушений лесного покрова	1. Простота расчета 2. Большой опыт применения	1. Сложность применения для снимков высокого разрешения (детальнее 10 м). 2. Учет только спектральных признаков нарушений
«Новые» методы выявления нарушений лесного покрова с помощью алгоритмов машинного обучения	1. Возможность обучения алгоритма, т. е. выявление новых случаев, отсутствующих в выборке. 2. Выявление структуры во входных данных. 3. Одновременная интерпретация разных групп признаков (текстурных, геометрических и др.)	1. Необходимость большой обучающей выборки. 2. Высокие требования к вычислительным мощностям (особенно при обработке ДДЗ). 3. Небольшой опыт применения

Для непосредственной реализации мониторинга необходимо использовать автоматические методы обработки ДДЗ. Их разработка ведется уже несколько десятилетий. В их числе одноканальное и многоканальное обнаружение изменений, разностные вегетационные индексы, сравнение классификаций разновременных снимков и др., однако эти методы имеют ряд ограничений.

В то же время, появляются методы машинного обучения, имеющие ряд преимуществ по сравнению с традиционными методами. Они увеличивают точность выявления нарушений лесного покрова, прежде всего за счет совместного анализа разных групп дешифровочных признаков (как спектральных, так и геометрических). Это позволяет выявлять выборочные и проходные рубки, что является главной проблемой при использовании «традиционных» методов выявления нарушений лесного покрова. Однако в настоящее время опубликовано немного исследований, посвященных использованию этих алгоритмов для выявления нарушений лесного покрова.

Методы машинного обучения требуют значительных вычислительных ресурсов, а также объемной обучающей выборки для

успешного применения. Доступность программно-аппаратных средств сейчас высока, появляются сервисы, которые предоставляют свои ресурсы для вычислений (облачные платформы Amazon, GoogleEarthEngine и др.), а в открытом доступе находится большое число обучающих выборок, в том числе с данными PlanetScope, Sentinel-2 (BigEarth dataset, PlanetLabs Competition), которые возможно использовать для построения собственных моделей. С другой стороны, для снижения объема необходимой обучающей выборки можно использовать ансамблевые методы.

В целом применение методов машинного обучения обладает большим потенциалом. Нейросетевые технологии являются де-факто стандартом в компьютерном зрении, так как они обеспечивают решение задач с очень высокой точностью. По сути обработка ДДЗ является частным случаем обработки изображений, поэтому применение методов машинного обучения для ведения оперативного картографирования обладает высокой степенью актуальности.

*Исследование проведено при финансовой поддержке гранта РФФИ № 19-35-90005.*

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Берлянт А. М. Теория геоизображений. – М. : ГЕОС, 2006.  
2. Салищев К. А. Картоведение. – М. : МГУ, 1990.

3. Remote sensing estimates of stand-replacement fires in Russia 2002–2011 / A. Krylov, J. L. McCarty, P. Potapov, T. Loboda, A. Tyukavina, S. Turubanova, M. C. Hansen // Envi-

- ronmental Research Letters. – 2014. – Vol. 9 (10). – Art. No. 105007.
4. Лесные пожары на территории России: особенности пожароопасного сезона 2019 г. / Е. А. Лупян, И. В. Балашов, С. А. Барталев, М. А. Бурцев, В. В. Дмитриев, К. С. Сенько, Ю. С. Крашенинникова // *Современные проблемы дистанционного зондирования Земли из космоса*. – 2019. – Т. 16, № 5. – С. 356–363.
5. Modelling natural disturbances in forest ecosystems: A review / R. Seidl, P. M. Fernandes, T. F. Fonseca, F. Gillet, A. M. Jönsson, K. Merganičová, S. Netherer, A. Arpacı, J.-D. Bontemps, H. Bugmann, J. R. González-Olabarria, P. Lasch, C. Meredieu, F. Moreira, M.-J. Schelhaas, F. Mohren // *Ecological Modelling*. – 2011. – Vol. 222 (4). – P. 903–924.
6. Крылов А. М., Соболев А. А., Владимирова Н. А. Выявление очагов короёда-типографа в Московской области с использованием снимков Landsat // *Лесной вестник*. – 2011. – № 4. – С. 54–60.
7. Eastern Europe's forest cover dynamics from 1985 to 2012 quantified from the full Landsat archive / P. V. Potapov, S. A. Turubanova, A. Tyukavina, A. M. Krylov, J. L. McCarty, V. C. Radeloff, M. C. Hansen // *Remote Sensing of Environment*. – 2015. – Vol. 159. – P. 28–43.
8. Williams D. L., Stauffer M. L. Monitoring gypsy moth defoliation by applying change detection techniques to Landsat imagery // *Proceedings of symposium on Remote Sensing for Vegetation Damage Assessment*. – Seattle, United States, 1978. – P. 221–229.
9. Sayn-Wittgenstein L., Wightman J. M. Landsat application in Canadian forestry // *Proceeding of the 10th International Symposium on Remote Sensing of Environment*. – Michigan, United States, 1975. – Vol. 2. – P. 1209–1218.
10. Hardisky M. A., Klemas V., Smart R. M. The influence of soil salinity, growth form and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies // *Photogrammetric engineering and remote sensing*. – 1983. – Vol. 49, № 1. – P. 77–83.
11. Крылов А. М., Владимирова Н. А. Дистанционный мониторинг состояния лесов по данным космической съемки [Электронный ресурс] // *Геоматика*. – 2011. – № 3. – С. 53–58. – Режим доступа: <http://geomatika.ru/clauses/282/>.
12. Post-hurricane forest damage assessment using satellite remote sensing / W. Wang, J. J. Qu, X. Hao, Y. Liu, J. A. Stanturf // *Agricultural and Forest Meteorology*. – 2010. – Vol. 150. – P. 122–132.
13. Cocke A. E., Fulé P. Z., Crouse J. E. Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data // *International Journal of Wildland Fire*. – 2005. – Vol. 14 (2). – P. 189–198.
14. Crist E. P., Laurin R., Cicone R. C. Vegetation and soils information contained in transformed Thematic Mapper data // *Proceedings of International Geosciences and Remote Sensing Symposium (IGARSS)* – Paris, France. 1986. – P. 1465–1470.
15. Wang F., Xu Y. J. Comparison of remote sensing change detection techniques for assessing hurricane damage to forests // *Environmental Monitoring and Assessment*. – 2010. – Vol. 162. – P. 311–326.
16. Nielsen A. A., Conradsen K., Simpson J. J. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies // *Remote Sensing of Environment*. – 1998. – Vol. 64 (1). – P. 1–9.
17. ScanEx Image Processor v.5.1. Программа обработки данных дистанционного зондирования Земли. Руководство пользователя. – М., 2018. – 379 с.
18. Coppin P. R., Bauer M. E. Processing of multi-temporal Landsat TM imagery to optimize extraction of forest cover change features // *IEEE Transactions on Geoscience and Remote Sensing*. – 1994. – Vol. 32. – P. 918–927.
19. Allen T. R., Kupfer J. A. Spectral response and spatial pattern of Fraser fir mortality and regeneration, Great Smoky Mountains, USA // *Plant Ecology*. – 2001. – Vol. 156. – P. 59–74.
20. High-Resolution Global Maps of 21st-Century Forest Cover Change / M. C. Hansen, P. V. Potapov, R. Moore, M. Hancher, S. A. Turubanova, A. Tyukavina, D. Thau, S. V. Stehman, S. J. Goetz, T. R. Loveland, A. Kommareddy, A. Egorov, L. Chini, C. O. Justice, J. R. G. Townshend // *Science*. – 2013. – Vol. 342. – P. 850–853.
21. Исследование возможностей оценки состояния поврежденных пожарами лесов по данным многоспектральных спутниковых измерений / С. А. Барталев, В. А. Егоров, А. М. Крылов, Ф. В. Стыценко, Т. С. Ховратович // *Современные проблемы дистанционного зондирования Земли из космоса*. – 2010. – Т. 7, № 3. – С. 215–225.
22. Крылов А. М., Малахова Е. Г., Владимирова Н. А. Выявление и оценка площадей катастрофических ветровалов 2009–2010 гг. по данным космической съемки // *Изв. Санкт-Петербургской лесотехнической академии*. – 2012. – № 200. – С. 197–207.
23. Королева Н. В., Ершов Д. В. Оценка погрешности определения площадей ветровалов по космическим изображениям высокого простран-

ственного разрешения LANDSAT-TM // Современные проблемы дистанционного зондирования Земли из космоса. – 2012. – Т. 9, № 1. – С. 80–86.

24. Landsat remote sensing of forest windfall disturbance / M. Baumann, M. Ozdogan, P. T. Wolter, A. M. Krylov, N. A. Vladimirova, V. C. Radelo // Remote Sensing of Environment. – 2014. – Vol. 143. – P. 171–179.

25. Huo L.-Z., Boschetti L., Sparks A. M. Object-based classification of forest disturbance types in the conterminous United States // Remote Sensing. – 2019. – Vol. 11 (5). – Art. No. 477.

26. Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain // Psychol. Rev. – 1958. – Vol. 65. – P. 386–408.

27. Goodfellow I., Bengio Y., Courville A. Deep learning. – MIT Press, 2016.

28. Samuel A. L. Some Studies in Machine Learning Using the Game of Checkers // IBM JOURNAL. – 1959. – Vol. 3, Issue 3. – P. 210–229.

29. Mitchell T. M. Machine learning. – New York: McGraw–Hill, 1997.

30. Krizhevsky A., Sutskever I., Hinton E. G. ImageNet Classification with Deep Convolutional Neural Networks // Proceedings of the 25th International Conference on Neural Information Processing Systems (issue 25). – New York, United States, 2012. – P. 1097–1105.

31. Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors / Z. Li, H. Shen, Q. Cheng, Y. Liu, S. You, Z. He // ISPRS Journal of Photogrammetry and Remote Sensing. – 2019. – Vol. 150. – P. 197–212.

32. Evaluation of the potential of convolutional neural networks and random forests for multi-class segmentation of Sentinel-2 imagery / V. Syrris, P. Hasenohr, B. Delipetrev, A. Kotsev, P. Kempe-

neers, P. Soille // Remote Sensing, – 2019. – Vol. 11(8). – Art. No. 907.

33. A machine learning approach to map tropical selective logging / M. G. Hethcoat, D. P. Edwards, J. M. B. Carreiras, R. G. Bryant, F. M. França, S. Quegan // Remote Sensing of Environment. – 2019. – Vol. 221. – P. 569–582.

34. Maximizing forest value through using Sentinel-2 in combination with hyperspectral UAVs / C. Aas, A. Jochemsen, V. Mantas, N. Lewyckyj, M. Jozefiak, M. Buchhorn // Proceedings of the 69th International Astronautical Congress. – Bremen, Germany, 2018. – P. 4492–4498.

35. Silvisense [Electronic resource]. – Mode of access: <https://silvisense.com/>.

36. Sub weekly detection of deforestation with planet data [Electronic resource] // Medium. – Mode of access: <https://medium.com/planet-stories/sub-weekly-detection-of-deforestation-with-planet-data-7699553b3926>.

37. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention / Navab N., Hornegger J., Wells W., Frangi A. (Eds). – MICCAI, 2015.

38. Banko M., Brill E. Scaling to Very Very Large Corpora for Natural Language Disambiguation // Proceedings of the 39th Annual Meeting of the Association for Computational Linguistics. – Toulouse, France. 2001. – P. 26–33.

39. Comparison of different convolutional neural network architectures for satellite image segmentation / V. Khryashchev, L. Ivanovisky, V. Pavlov, A. Rubtsov, A. Ostrovskay // Proceeding of the 23rd conference of fruct association. – Jyvaskyla, Finland, 2018. – P. 172–180.

40. Russakovsky O., Deng J., Su H. ImageNet large-scale visual recognition challenge, 2010–2015. – 2015.

Получено 11.03.2020

© А. В. Тарасов, 2020

## TRADITIONAL AND MODERN METHODS OF SATELLITE IMAGES PROCESSING FOR OPERATIONAL MAPPING OF FOREST COVER DISTUBANCES

*Andrey V. Tarasov*

Perm State University, 15, Bukireva St., Perm, 614990, Russia, Ph. D. Student, Department of Cartography and Geoinformatics, e-mail: [andrew.tarasov1993.study@gmail.com](mailto:andrew.tarasov1993.study@gmail.com)

Real-time mapping of forest disturbances is important for forest management. Detection of forest stands damaged by natural or human-induced factors allows making immediate necessary management decisions. To implement such a management strategy, it is necessary to use the methods of operational mapping. With the advent of the Earth remote sensing data (RSD), which have high spatial and temporal resolution (Planet

Scope and Sentinel-2), it becomes possible to implement modern operational mapping methods for forest management operations (particularly, forest disturbance detection). Since the monitoring area and the number of images sharply increases, the need for automated image processing methods also rises. This paper provides an overview of “traditional methods” for identifying forest cover disturbances (vegetation indexes, Tasseled Cap, multiband and single band change detection etc), their basis, limitations, and experience of their application in Russia and in the world. Instead, algorithm based on machine learning methods and their classification are presented. Benefits and limitations of both groups of forest disturbances detection algorithms are noted. In addition, it was found out that there is limited experience of application of machine learning algorithms for RSD processing and such kind of research is relevant.

**Key words:** real-time mapping, processing methods of remote sensing data, Planet Scope, Sentinel-2, machine learning.

## REFERENCES

1. Berlyant, A. M. (2006). *Teoriya geozobrazheniy [Geoimages theory]*. Moscow: GEOS Publ. [in Russian].
2. Salishev, K. A. (1990). *Kartovedenie [Cartography]*. Moscow: MSU Publ. [in Russian].
3. Krylov, A., McCarty, J. L., Potapov, P., Loboda, T., Tyukavina, A., Turubanova, S. & Hansen, M. C. (2014). Remote sensing estimates of stand-replacement fires in Russia 2002–2011. *Environmental Research Letters*, 9(10), Art. No. 105007.
4. Loupian, E. A., Balashov, I. V., Bartalev, S. A., Byrtsev, M. A., Dmitriev, V. V., Senko, K. S. & Krasheninnikova Y. S. (2019). Forest fires in Russia: features of the 2019 fire season. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa [Modern Problems of Remote Sensing of the Earth from Space]*, 16(5), 356–363 [in Russian].
5. Seidl, R., Fernandes, P. M., Fonseca, T. F., Gillet, F., Jönsson, A. M., Merganičová, K., Netherer, S., Arpacı, A., Bontemps, J.-D., Bugmann, H., González-Olabarria, J. R., Lasch, P., Meredieu, C., Moreira, F., Schelhaas, M.-J. & Mohren, F. (2011). Modelling natural disturbances in forest ecosystems: A review. *Ecological Modelling*, 222(4), 903–924.
6. Krylov, A. M., Sobolev, A. A., & Vladimirova, N. A. (2011). Identification seat of a bark beetle typhograph in the Moscow region using Landsat images. *Lesnoy vestnik [Forest Bulletin]*, 4, 54–60 [in Russian].
7. Potapov, P. V., Turubanova, S. A., Tyukavina, A., Krylov, A. M., McCarty, J. L., Radeloff, V. C., & Hansen, M. C. (2015). Eastern Europe's forest cover dynamics from 1985 to 2012 quantified from the full Landsat archive. *Remote Sensing of Environment*, 159, 28–43.
8. Williams, D. L., & Stauffer, M. L. (1978) Monitoring gypsy moth defoliation by applying change detection techniques to Landsat imagery. In *Proceedings of symposium on Remote Sensing for Vegetation Damage Assessment* (pp. 221–229). Seattle, United States.
9. Sayn-Wittgenstein, L., & Wightman, J. M. (1975). Landsat application in Canadian forestry. In *Proceeding of the 10th International Symposium on Remote Sensing of Environment* (pp. 1209–1218). Michigan, United States.
10. Hardisky, M. A., Klemas, V., & Smart R. M. (1983). The influence of soil salinity, growth form and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49(1), 77–83.
11. Krylov, A. M., & Vladimirova, N. A. (2011). Space based monitoring of forest health. *Geomatika [Geomatics]*, 3, 53–58.
12. Wang, W., Qu, J. J., Hao, X., Liu, Y., & Stanturf, J. A. (2010) Post-hurricane forest damage assessment using satellite remote sensing. *Agricultural and Forest Meteorology*, 150, 122–132.
13. Cocke, A. E., Fulé, P. Z., & Crouse, J. E. (2005). Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data. *International Journal of Wildland Fire*, 14(2), 189–198.
14. Crist, E. P., Laurin, R., & Cicone, R. C. (1986). Vegetation and soils information contained in transformed Thematic Mapper data. In *Proceedings of International Geosciences and Remote Sensing Symposium (IGARSS)* (pp. 1465–1470). Paris, France.
15. Wang, F., & Xu, Y. J. (2010). Comparison of remote sensing change detection techniques for assessing hurricane damage to forests. *Environmental Monitoring and Assessment*, 162, 311–326.
16. Nielsen, A. A., Conradsen, K., & Simpson, J. J. (1998). Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies. *Remote Sensing of Environment*, 64(1), 1–9.
17. ScanEx Image Processor v.5.1. (2018). Software for remote sensing data processing. Manual. Moscow, 379 p.
18. Coppin, P. R., & Bauer, M. E. (1994). Processing of multi-temporal Landsat TM imagery to optimize extraction of forest cover change features. *IEEE Transactions on Geoscience and Remote Sensing*, 32, 918–927.

19. Allen, T. R., & Kupfer, J. A. (2001). Spectral response and spatial pattern of Fraser fir mortality and regeneration, Great Smoky Mountains, USA. *Plant Ecology*, 156, 59–74.
20. Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O., & Townshend, J. R. G. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342, 850–853.
21. Bartalev, S. A., Egorov, V. A., Krylov, A. M., Stycenko, F. V., & Chovratovich T. S. (2010). Research of possibility to estimate post-fired forest condition according to multispectral satellite images. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa [Modern Problems of Remote Sensing of the Earth from Space]*, 7(3), 215–225 [in Russian]
22. Krylov, A. M., Malahova, E. G., & Vladimirova, N. A. (2012). Detection and estimation of areas of catastrophic windthrows 2009–2010 according to space imagery data. *Izvestiya Sankt-Peterburgskoi lesotechnicheskoi akademii [Bulletin of the St. Petersburg Forestry Academy]*, 200, 197–207 [in Russian].
23. Koroleva, N. V., & Ershov, D. V. (2012). Estimation of error of windthrow area detection according to space images with high spatial resolution LANDSAT-TM. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa [Modern Problems of Remote Sensing of the Earth from Space]*, 9(1), 80–86 [in Russian].
24. Baumann, M., Ozdogan, M., Wolter, P. T., Krylov, A. M., Vladimirova, N. A., & Radeloff, V. C. (2014). Landsat remote sensing of forest windfall disturbance. *Remote Sensing of Environment*, 143, 171–179.
25. Huo, L.-Z., Boschetti, L. & Sparks, A. M. (2019). Object-based classification of forest disturbance types in the conterminous United States. *Remote Sensing*, 11(5), Art. No. 477.
26. Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychol. Rev.*, 65, 386–408.
27. Goodfellow I., Bengio Y., & Courville A. (2016). Deep learning. MIT Press.
28. Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM JOURNAL*, 3(3), 210–229.
29. Mitchell, T. M. (1997). Machine learning. New York: McGraw–Hill.
30. Krizhevsky, A., Sutskever, I. & Hinton, E. G. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In *Proceedings of the 25th International Conference on Neural Information Processing Systems* (pp. 1097–1105). New York, United States.
31. Li, Z., Shen, H., Cheng, Q., Liu, Y., You, S., & He, Z. (2019). Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 197–212.
32. Syrri, V., Hasenohr, P., Delipetrev, B., Kotsev, A., Kempeneers, P., & Soille, P. (2019). Evaluation of the potential of convolutional neural networks and random forests for multi-class segmentation of Sentinel-2 imagery. *Remote Sensing*, 11(8), Art. No. 907.
33. Hethcoat, M. G., Edwards, D. P., Carreiras, J. M. B., Bryant, R. G., França, F. M., & Quegan, S. (2019). A machine learning approach to map tropical selective logging. *Remote Sensing of Environment*, 221, 569–582.
34. Aas, C., Jochemsen, A., Mantas, V., Lewycky, N., Jozefiak, M., & Buchhorn, M. (2018). Maximizing forest value through using Sentinel-2 in combination with hyperspectral UAVs. In *Proceedings of the 69th International Astronautical Congress* (pp. 4492–4498). Bremen, Germany.
35. Silvisense. (n. d.). Retrieved from <https://silvisense.com/>.
36. Sub weekly detection of deforestation with planet data. Retrieved from <https://medium.com/planet-stories/sub-weekly-detection-of-deforestation-with-planet-data-7699553b3926>.
37. Ronneberger, O., Fischer, P., & Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science: Vol 9351*. N. Navab, J. Hornegger, W. Wells, & A. Frangi (Eds.). Springer, Cham.
38. Banko, M., & Brill, E. (2001). Scaling to Very Very Large Corpora for Natural Language Disambiguation. In *Proceedings of the 39th Annual Meeting of the Association for Computational Linguistics* (pp. 26–33). Toulouse, France.
39. Khryashchev, V., Ivanovskiy, L., Pavlov, V., Rubtsov, A., & Ostrovskaya, A. (2018). Comparison of different convolutional neural network architectures for satellite image segmentation. In *Proceeding of the 23rd Conference of Fruct Association* (pp. 172–180). Jyväskylä, Finland.
40. Russakovsky, O., Deng J., & Su, H. (2015). ImageNet large-scale visual recognition challenge, 2010–2015.

Received 11.03.2020

© A. V. Tarasov, 2020