

(19)



**Евразийское  
патентное  
ведомство**

(11) **048245**(13) **B1**(12) **ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОМУ ПАТЕНТУ**(45) Дата публикации и выдачи патента  
**2024.11.12**(21) Номер заявки  
**202392932**(22) Дата подачи заявки  
**2023.11.16**(51) Int. Cl. **G01V 20/00** (2024.01)  
**G01S 17/04** (2020.01)  
**G01S 17/06** (2006.01)  
**G06T 17/05** (2011.01)  
**G06N 3/0464** (2023.01)(54) **СПОСОБ ОПРЕДЕЛЕНИЯ ОБЪЕКТОВ ЛАНДШАФТА НА СПУТНИКОВЫХ СНИМКАХ**(43) **2024.11.11**(96) **2023000187 (RU) 2023.11.16**(71)(73) Заявитель и патентовладелец:  
**ПУБЛИЧНОЕ АКЦИОНЕРНОЕ  
ОБЩЕСТВО "ГАЗПРОМ  
НЕФТЬ" (RU)**(72) Изобретатель:  
**Панов Роман Алексеевич, Шевелев  
Тихон Геннадьевич, Воротников  
Олег Николаевич, Мартухович  
Илья Олегович, Зотиков Леонид  
Николаевич (RU)**(74) Представитель:  
**Чугункина Л.А. (RU)**(56) **CN-B-113724389  
CN-A-113408468  
CN-A-105404753**Зарубин О.А. Применение нейронных сетей для целей анализа данных дистанционного зондирования Земли//СОВРЕМЕННЫЕ НАУЧНЫЕ ИССЛЕДОВАНИЯ И ИННОВАЦИИ. 2016, № 8 [онлайн][найден 2024-03-25], найден в <<https://web.snauka.ru/issues/2016/08/70887>> Весь документ  
**RU-C1-2489845**

(57) Изобретение относится к комплексному решению ряда задач, связанных с автоматизацией интеллектуального анализа спутниковых снимков, в частности к способу и системе для определения объектов ландшафта на спутниковых снимках земной поверхности, и направлено на выявление границ болот, лесных насаждений, облаков или водоемов, включая категоризацию объектов путем, например, оценки объема или типа биомассы или оценки обводненности. Заявленное изобретение может быть применено для определения объектов и их категорий по спутниковым снимкам с помощью алгоритмов машинного обучения и интеллектуального анализа данных. В частности, настоящее изобретение относится к способу определения объектов на спутниковых снимках, включающему следующие этапы: получают спутниковые снимки, выполняют предварительную обработку спутниковых снимков, включающую, по меньшей мере, определение на основе спектральных каналов спутниковых снимков одного или более спектральных индексов, которые представляют в виде карты спектральных индексов, подают спектральные каналы и карту спектральных индексов в предварительно обученный алгоритм машинного обучения, получают вероятностную карту объектов с помощью алгоритма машинного обучения, выполняют постобработку вероятностной карты объектов, включающую удаление шумов и артефактов, восстановление пропущенных участков в вероятностной карте объектов, получают карту объектов путем объединения вероятностной карты объектов и карты одного или более спектральных индексов, формируют слои размеченных объектов. Изобретение также относится к системе, содержащей по меньшей мере один процессор, оперативную память и машиночитаемые инструкции для выполнения способа определения объектов на спутниковых снимках. Техническим результатом заявленного изобретения является создание универсальных способа и системы определения объектов на спутниковых снимках, подходящих для определения объектов разных типов и обеспечивающих повышение эффективности и точности определения и анализа объектов на спутниковых снимках за счет более точной идентификации и последующей классификации, что позволяет, в свою очередь, получить более детальную информацию о местности без проведения полевых работ.

**B1****048245****048245****B1**

Настоящее изобретение относится к комплексному решению ряда задач, связанных с автоматизацией интеллектуального анализа спутниковых снимков, в частности к способу и системе для определения объектов на спутниковых снимках земной поверхности, и направлено на выявление границ болот, лесных насаждений, облаков или водоемов, включая категоризацию объектов путем, например, оценки объема или типа биомассы или оценки обводненности. Заявленное изобретение может быть применено для определения объектов и их категорий по спутниковым снимкам с помощью алгоритмов машинного обучения и интеллектуального анализа данных.

По мнению заявителя, наиболее близкими по технической сущности к заявленному изобретению являются описанные ниже решения.

В документе CN 113408468 А (дата публикации: 17.09.2021, МПК: G06K 9/00; G06K 9/34; G06K 9/62; G06N 3/00) раскрывается способ выявления лесных болот на основе спутникового снимка Sentinel и относится к способу распознавания и определения лесных болот с использованием данных дистанционного зондирования. Способ включает следующие этапы: скрининг для получения изображений Sentinel-1 GRD и Sentinel-2 MSI; получение изображения коэффициентов обратного рассеяния VV и VH в пространстве; вычисление индексных характеристик индекса красной границы, индекса растительности и индекса водного объекта изображения Sentinel-2; получение информации об отражательной способности исследовательской зоны Sentinel-2; извлечение обучающей выборки и модели точки проверки; идентификацию и извлечение информации о типе всей лесной болотистой местности в районе исследования и проверку точности; а также выявление площади лесных болот на территории исследования для получения информации о распространении лесных болот. Общими признаками известного и заявленного способов являются предварительная обработка спутниковых снимков и определение спектральных индексов. Однако, в данном известном способе не создают карту спектральных индексов для объединения с вероятностной картой объектов для категоризации или классификации определяемых объектов, в известном способе не определяются и не классифицируются различные виды объектов ландшафта.

В документе CN 113724389 А (дата публикации: 30.11.2017, МПК: G06T 17/05; G06F 16/29; G06K 9/62) раскрывается способ картографирования водно-болотных угодий, основанный на объектно-ориентированном иерархическом дереве решений. Способ включает следующие этапы: создание библиотеки образцов водно-болотных угодий на основе системы классификации водно-болотных угодий; загрузку изображений Landsat и данных DEM; расчет параметров; изменение связанных параметров сегментации до тех пор, пока не будет получен результат сегментации; построение иерархической системы классификации дерева решений; получение предварительного результата классификации; проведение коррекции результатов на основе исторических данных и ручной интерпретации; получение окончательного результата классификации и выполнение оценки точности. Общими признаками известного и заявленного способов также являются предварительная обработка спутниковых снимков и определение спектральных индексов. Однако из данного документа также не известно создание карты спектральных индексов для объединения с вероятностной картой с целью категоризации или классификации определяемых объектов, в известном способе также не определяются и не классифицируются различные виды объектов ландшафта.

В качестве прототипа заявителем рассматривается решение, известное из документа CN 105404753 А (дата публикации: 16.03.2016, МПК: G06F 17/50), где раскрывается способ картирования водно-болотных угодий, основанный на методе объектно-ориентированной случайной классификации лесов и изображении дистанционного зондирования среднего разрешения. Данный способ картирования водно-болотных угодий включает проведение радиометрической калибровки, атмосферной коррекции, орторектификации, точной геометрической коррекции и проекционного преобразования с использованием данных Landsat-8OLI; обработку данных с помощью программного обеспечения eCognition 8.6; удаление объектов "не болото" из водно-болотных объектов; установку порогового значения для разделения на типы болот (травянистые, кустарниковые, лесные); а затем составление тематической карты водно-болотных угодий в программном обеспечении ArcGIS 10.0. Общими признаками известного и заявленного способов является предварительная обработка спутниковых снимков, определение спектральных индексов, постобработка результатов работы программы и формирование результатов со слоями размеченных объектов. Однако в данном известном способе не применяется алгоритм машинного обучения и отсутствуют какие-либо сведения о возможности объединения карты спектральных индексов с результатами работы алгоритма для категоризации или классификации болот. Кроме того, в известном способе не обсуждается возможность определения степени обводненности болот, и он не может быть применен для определения объектов, отличных от водно-болотных угодий.

Описанные выше известные из уровня техники технические решения позволяют определить границы объектов, в частности болот, с определенной точностью, однако ни в одном из данных решений не обсуждается возможность более детального анализа объекта с точки зрения, например, обводненности болота. Кроме того, указанные решения позволяют определять исключительно водно-болотные объекты и не могут быть также применены для определения иных объектов ландшафта, то есть не обладают универсальностью в применении.

Техническим результатом заявленного изобретения является создание универсального способа оп-

ределения объектов на спутниковых снимках, подходящего для определения объектов разных типов и обеспечивающего повышение эффективности и точности определения и анализа объектов на спутниковых снимках за счет более точной идентификации и последующей классификации, что позволяет, в свою очередь, получить более детальную информацию о местности без проведения полевых работ.

Технический результат достигается благодаря способу определения объектов на спутниковых снимках, включающему в себя следующие этапы:

- получают спутниковые снимки,
- выполняют предварительную обработку спутниковых снимков, включающую, по меньшей мере, определение на основе спектральных каналов спутниковых снимков одного или более спектральных индексов, которые представляют в виде карты спектральных индексов,
- подают спектральные каналы и карту спектральных индексов в предварительно обученный алгоритм машинного обучения,
- получают вероятностную карту объектов с помощью алгоритма машинного обучения,
- выполняют постобработку вероятностной карты объектов, включающую удаление шумов и артефактов, восстановление пропущенных участков в вероятностной карте объектов,
- получают карту объектов путем объединения вероятностной карты объектов и карты одного или более спектральных индексов,
- формируют слои размеченных объектов.

Каждый спутниковый снимок включает множество спектральных каналов. Спектральный канал - это непрерывный относительно узкий участок спектрального диапазона, регистрируемый одним из датчиков спутника и отображаемый на одну цветовую плоскость. Спектральный же индекс представляет собой отношение, определенное на основании диапазонов спектральных каналов и позволяющее более точно определять объекты на спутниковых снимках. Однако в настоящем изобретении спектральные индексы применяются не только как входные данные для алгоритма машинного обучения, но и используются для классификации или категоризации выявленных объектов, например для определения степени обводненности болот, количества растительности на них, или же, например, для определения вида леса (лесистый ли лес, хвойный или смешанный). Данный технический результат достигается за счет объединения вероятностной карты объектов, полученной на выходе алгоритма машинного обучения, и карты одного или более из определенных спектральных индексов, которую в упрощенном виде можно представить как матрицу значений. Соответственно, под объединением карт подразумевается наложение значения спектрального индекса на значение, которое получили с использованием алгоритма машинного обучения, в каждом пикселе или тайле изображения (или карты). Значение результата данного объединения позволяет разделить объекты на категории, например, по степени обводненности или по типу леса, что и обеспечивает достижение указанного технического результата. Также благодаря данному объединению карт обеспечивается дополнительная верификация результатов, выдаваемых алгоритмом машинного обучения, что обеспечивает большую точность при определении объектов, в особенности их границ. Кроме того, заявленное изобретение обеспечивает универсальность в применяемых средствах и способах определения объектов, так как изобретение позволяет определить объекты различных типов (болота, леса, облачные участки, водные участки), а также классифицировать эти объекты (например, определить степень заболоченности или тип леса), за счет предварительного обучения алгоритма машинного обучения на данных обучающих выборках.

Также технический результат достигается за счет того, что система определения объектов на спутниковых снимках, содержащая по меньшей мере один процессор, оперативную память и машиночитаемые инструкции, выполняет следующие этапы:

- получают спутниковые снимки,
- выполняют предварительную обработку спутниковых снимков, включающую, по меньшей мере, определение на основе спектральных каналов спутниковых снимков одного или более спектральных индексов, которые представляют в виде карты спектральных индексов,
- подают спектральные каналы и карту спектральных индексов в предварительно обученный алгоритм машинного обучения,
- получают вероятностную карту объектов с помощью алгоритма машинного обучения,
- выполняют постобработку вероятностной карты объектов, включающую удаление шумов и артефактов, восстановление пропущенных участков в вероятностной карте объектов,
- получают карту объектов путем объединения вероятностной карты объектов и карты одного или более спектральных индексов,
- формируют слои размеченных объектов.

При реализации изобретения в качестве алгоритма машинного обучения может быть использована сверточная нейронная сеть. Нейросетевые модели способны адаптироваться под сложные и нелинейные соотношения между различными спектральными каналами. Благодаря этому отпадает необходимость в явном использовании спектральных индексов в качестве входных признаков: как правило они представляют собой относительно простую взаимосвязь между двумя спектральными каналами. В случае, если такая информация является значимой, подобная закономерность устанавливается непосредственно в

процессе обучения нейросетевой модели в неявном виде. Уменьшение количества слоев в исходных данных позволяет обучать более глубокие модели за меньшее время, что положительно сказывается на результате.

При реализации изобретения этап предварительной обработки также может включать удаление шумов и артефактов и восстановление пропущенных участков в спутниковых снимках, что позволяет обеспечить более точное определение объекта и его классификацию.

При реализации изобретения объектами определения могут являться болота, при этом их определяют путем объединения вероятностной карты объектов, карты нормализованного разностного индекса влажности NDMI, карты нормализованного относительного вегетационного индекса NDVI и карты нормализованного разностного водного индекса NDWI.

При реализации изобретения могут быть определены один или более из следующих спектральных индексов: нормализованный относительный вегетационный индекс NDVI, нормализованный разностный индекс влажности NDMI, нормализованный разностный водный индекс NDWI, модифицированный разностный водяной индекс mNDWI.

При реализации изобретения могут быть дополнительно определены по меньшей мере две степени обводненности болот, для чего формируют карту степени обводненности участков болот путем объединения вероятностной карты объектов и карты нормализованного разностного индекса влажности NDMI.

При реализации изобретения для определения степени заболоченности дополнительно может быть объединена вероятностная карта объектов и карта топографического индекса влажности TWI, определенного на основании цифровой модели рельефа (ЦМР). Индекс TWI может служить еще одним источником информации, способствующим улучшению качества распознавания болот. Сама по себе ЦМР не может использоваться для распознавания и классификации болот, но топографический индекс влажности (TWI), рассчитанный на ее основе, существенно улучшает точность результатов распознавания по данным спутниковых снимков. Индекс TWI показывает предрасположенность того или иного участка местности к накоплению воды. Авторами изобретения было обнаружено, что данный индекс оказался очень информативным для определения болот. Положительные значения TWI - большая предрасположенность к накоплению воды, а отрицательные значения - большая предрасположенность к отторжению воды (сток с этих участков). Таким образом, использование данного индекса помогает выделять места, наиболее вероятные для естественного образования заболоченности, а также помогает исключить результаты ложного определения, вызванного тенью или другими артефактами изображения.

При реализации изобретения объектами определения могут являться леса, при этом их определяют путем объединения вероятностной карты объектов и карты нормализованного относительного вегетационного индекса NDVI.

При реализации изобретения возможно определение типа леса. Для определения типа леса объединяют вероятностную карту объектов, карту нормализованного относительного вегетационного индекса NDVI и карту модифицированного разностного водяного индекса mNDWI.

При реализации изобретения объектами определения могут являться водные участки, при этом их определяют путем объединения вероятностной карты объектов и карты нормализованного разностного водного индекса NDWI.

При реализации изобретения объектами определения могут являться облачные участки, при этом их определяют путем объединения вероятностной карты объектов и карты нормализованного разностного водного индекса NDWI. Определение облачных участков на спутниковых снимках может быть применено для удаления скрытых облаками участков и замены их участками той же местности, но которые видны на другом спутниковом снимке, то есть для своего рода совмещения данных с нескольких спутниковых снимков с целью получения карты местности без облачности.

Для решения задачи сегментации (т.е. классификации каждого пикселя) выбранной области используется алгоритм машинного обучения. Для этого проводится предварительное обучение алгоритма - формируется обучающая выборка, содержащая примеры как наличия болот, так и их отсутствия. Исходные данные определяются спектральными каналами спутниковых спутников и определенными на их основе спектральными индексами (такими как, например, нормализованный относительный вегетационный индекс NDVI, нормализованный разностный индекс влажности NDMI, нормализованный разностный водный индекс NDWI, модифицированный разностный водяной индекс mNDWI) или иными индексами (например, TWI). После нарезки исходных данных первая часть будет отнесена к тренировочной выборке, вторая часть - к валидационной выборке, третья - к тестовой. Полученные данные стандартизируются: по тренировочной выборке определяются значения среднего и дисперсии для каждого признака, далее эти значения используются для стандартизации всех полученных ранее выборок. Для каждой выборки происходит нарезка на квадратные тайлы. Алгоритм в процессе обучения устанавливает соответствие между исходными данными (спектральные каналы и карта спектральных индексов) и их метками целевого класса (т.е. особыми признаками или видом, характеризующими объект на спутниковом снимке), которое может быть экстраполировано на области, не входящие в тренировочную выборку. В качестве алгоритма может быть использована сверточная нейронная сеть. Основное преимущество сверточных нейронных сетей перед большинством классических методов заключается в эффективном учете про-

странственного (и даже признакового) контекста распознаваемых образов. Особенность сверточной сети по сравнению с полносвязными заключается в эффективном использовании пространственной информации вокруг классифицируемых пикселей, что позволяет учитывать даже морфологические признаки, которые в отдельных случаях могут содержать важную информацию для сегментации заболоченных территорий. В качестве альтернативы может использоваться, например, метод опорных векторов или иной тип нейронной сети.

Для искусственного расширения объема используемой обучающей выборки, а также улучшения свойства обобщаемости модели используется техника аугментирования. Аугментация - это набор рандомизированных преобразований, относительно которых исследуемый целевой класс должен быть инвариантным. Помимо классических преобразований, таких как поворот, отражение и случайное изменение яркости, может использоваться трансформация искажения сетки. Данное преобразование изменяет локальные пропорции изображения, случайным образом сжимая/растягивая изображение вдоль ортогональных осей.

После выполнения обучения алгоритм способен, на основании спектральных каналов и определенных индексов (конкретный набор индексов зависит от поставленной задачи), определять объекты, представляющие интерес, и, кроме того, за счет объединения результатов вероятностной карты объектов и одной или нескольких карт определенных индексов получать карту объектов, в которой объекты могут быть классифицированы по выбранному признаку (например, степени обводненности).

Изобретение поясняется следующими чертежами.

На фиг. 1 представлена блок-схема системы для определения объектов по спутниковым снимкам.

На фиг. 2 представлены индексы, которые могут быть определены на этапе предварительной подготовки. По часовой стрелке, начиная с левого верхнего угла: NDVI, NDMI, TWI, NDWI. Большим значениям индекса соответствует желтый цвет, низким - темно-синий.

На фиг. 3 представлена визуализация цифровой модели рельефа (ЦМР) и значений TWI. Оранжевый цвет соответствует низким значениям TWI, синий - высоким.

На фиг. 4 представлен пример нарезки области предсказания (границы выделены красным) на квадратные сегменты.

На фиг. 5 представлен результат предсказания алгоритмом, выполняющим предсказания для каждой квадратной области (в местах наложения областей происходит усреднение предсказаний), то есть вероятностная карта объектов.

На фиг. 6 представлено предсказание болот с оценкой обводненности - полученная вероятностная карта объединяется с картой индекса NDMI, чтобы получить оценку обводненности болот. Более светлые участки соответствуют более влажным участкам местности.

На фиг. 7 представлена категоризация заболоченных участков. Светло-фиолетовые области соответствуют регионам со слабой заболоченностью, а желтые - средней.

На фиг. 8 представлены предсказанные полигоны контуров заболоченных областей, полученных в результате бинаризации карты значений обводненности, и определения на ее основе контуров болот.

На фиг. 9 представлен финальный результат после обработки алгоритмом и наложения бинарной маски на карту местности, то есть карта местности представлена со слоями размеченных объектов. Коричневыми полигонами отмечены болота, а красными полигонами отмечены их наиболее влажные участки.

Ниже приведен пример осуществления, в котором с использованием алгоритма машинного обучения определяют и классифицируют болота, однако специалисту в данной области техники будет очевидно, что заявленное изобретение может быть применено и для других задач, например определения границ обводненности, лесистости, определения типа леса, определения наличия облаков на спутниковых снимках и т.д. Основные блоки системы для осуществления способа продемонстрированы на фиг. 1.

Используемая здесь в качестве примера сверточная нейронная модель - это модификация классической U-net архитектуры, которая называется U-net++. Основная идея оригинальной архитектуры заключается в наличии двух структур - кодировщика и декодировщика. Кодировщик при помощи множественных операций свертки выделяет основную семантическую информацию из исходных данных, преобразуя их в матрицы весов. Далее декодировщик восстанавливает из такого набора признаков сегментированное изображение. В качестве кодировщика и декодировщика в моделях такого типа могут применяться также различные архитектуры. В качестве альтернативы, могут использоваться и иные нейросетевые архитектуры, например U-Nets (UNet++, SWIN-UNet), ResNets (SE-ResNet, Inception ResNet), DeepLabV3+, и различные алгоритмы классического машинного обучения, например Gradient Boosting, Random Forest, DBSCAN, PCA, KDA, One-Class SVM, bayessian search, Conditional Random Fields.

Для решения задачи зонирования болот и определения степени обводненности необходимы следующие исходные данные:

спутниковый снимок Sentinel-2A или Sentinel-2B или любое другое спутниковое изображение, охватывающее интересующую область и имеющее спектральные каналы, эквивалентные следующим каналам Sentinel-2: B03 (Green), B04 (Red), B08 (NIR), B8A (Narrow NIR), B11 & B12 (SWIR), и индексы, определенные на основе данных со спутникового снимка: NDVI, NDMI, NDWI, TWI.

Ниже приведены формулы расчета данных индексов:

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

$$NDMI = \frac{NIR - SWIR}{NIR + SWIR}$$

$$NDWI = \frac{Green - NIR}{Green + NIR}$$

$$TWI = \ln \frac{(DEM_{acc} + 1) \cdot r}{\tan(DEM_{slope})}$$

Здесь Green - видимый зеленый диапазон электромагнитного спектра,

Red - видимый красный диапазон электромагнитного спектра,

NIR - ближний инфракрасный диапазон,

SWIR - коротковолновый инфракрасный диапазон,

DEM<sub>acc</sub> - алгоритмически рассчитанные по ЦМР значения накопления потока,

r - разрешение данных ЦМР,

DEM<sub>slope</sub> - значения угла наклона ЦМР (в радианах).

Спектральные индексы можно представить в виде матрицы, где каждому пикселу (или тайлу) присвоено конкретное значение. Визуальные отображения спектральных индексов представлены на фиг. 2 и 3.

Помимо определения требуемых спектральных индексов на этапе предварительной обработки спутниковых снимков могут выполняться следующие шаги (которые выбираются в зависимости от поставленной задачи):

применение алгоритма билинейной интерполяции;

объединение полученных данных с формированием растров признаков с заданной размерностью;

присвоение каждому растру признаков растеризированной бинарной маски целевого класса,

удаление шумов (например, с помощью морфологических преобразований сужения и расширения)

и артефактов и восстановление пропущенных участков в спутниковых снимках (например, с помощью статистического анализа связанных компонент растрового изображения);

Далее предварительно обработанные данные подаются на вход предварительно обученного алгоритма машинного обучения в данном примере сверточной нейронной сети. Предварительное обучение алгоритма машинного обучения выполняется следующим образом. Обучающий набор данных состоит из набора снимков с разметкой объектов для определения, причем разметка производится полуавтоматическим методом, то есть сначала маска объекта создается автоматически, а затем полученная маска вручную корректируется с привлечением снимков сверхвысокого разрешения. Таким образом получается обучающая выборка с, например, следующей комбинацией каналов: R (красный) + G (зеленый) + B (голубой) + NIR (ближний инфракрасный) + SWIR (коротковолновый инфракрасный) + спектральный индекс, выбираемый в зависимости от определяемого объекта. Процесс обучения многократно повторяется, после чего в алгоритме машинного обучения выбираются параметры, при которых достигается наибольшая точность на валидационной выборке.

Для определения класса объекта алгоритм изначально разбивает изображение на более мелкие части - сегменты так, чтобы их длины не превосходили заранее определенного значения, как показано на фиг. 4. Затем каждая часть сегмента равномерно разбивается несколькими точками, для каждой из которых создаются небольшие растеризированные квадратные области (центром которых являются эти точки) при различных масштабах. Для классификации сегмента модель разбивает исходный сегмент на части фиксированной длины, и для равномерно выбранных точек внутри каждой части выполняется предсказание для каждой квадратной области в сегменте с центрами в этих точках. Далее обученная сверточная нейронная сеть совершает предсказание на всех таких прямоугольных областях, и полученные предсказания в каждом сегменте усредняются, как показано на фиг. 5. Таким образом, модель "проходит" вдоль каждого сегмента по квадратным областям внутри него и использует одновременно несколько масштабов, что позволяет получать достаточно робастные относительно случайных шумов в исходных данных результаты.

Полученные предсказания модели представляют из себя значения каждого пикселя в диапазоне 0-1, которые неформально можно интерпретировать (с точностью до калибровки), как "уверенность" модели в наличии целевого класса. Эти значения бинаризируются по эмпирически подобранному порогу, с получением бинарной маски заболоченных территорий. Соответственно, на выходе нейросетевой модели формируется вероятностная карта заболоченности, пример которой представлен на фиг. 5. Каждый пиксель вероятностной карты принимает значения в диапазоне от 0 до 1, которые можно интерпретировать как уверенность модели в том, что данный пиксель относится к классу болот.

Далее выполняется постобработка полученных результатов, включающая удаление шумов и артефактов и восстановление пропущенных участков. Удаление шумов и артефактов может выпол-

няться, например, с помощью морфологических преобразований сужения (представляющих собой своего рода размывание изображения с целью избавления от вкраплений шума; при размывании мелкие вкрапления шумов устраняются, тогда как крупные объекты остаются) и расширения (представляющих собой растягивание изображения один или несколько раз с целью избавиться от вкраплений шума, то есть области, разделенные вкраплениями шума, объединяют друг другом и исключают вкрапления). Восстановление пропущенных участков осуществляется, например, с помощью статистического анализа связанных компонент растрового изображения, то есть информация о пространстве вокруг пропущенного участка анализируется, и на основании данной информации пропущенный участок заполняется теми же данными, что и в пространстве вокруг. Для получения наилучших результатов данные операции могут быть выполнены также и на этапе предварительной обработки.

Далее формируется карта обводненности болот исследуемого участка. Для этого полученная на предыдущем этапе вероятностная карта (после постобработки) заболоченности объединяется путем наложения с картой спектрального индекса NDMI, который существенно коррелирует с наличием влаги в почве. В данной карте спектрального индекса всем пикселям со значениями меньше 0 (что соответствует сухим участкам) присваивается значение ноль. Полученный из алгоритма машинного обучения растр предсказания (который можно представить в виде матрицы со значениями от 0 до 1) объединяется со значениями индекса NDMI, чтобы получить оценку обводненности болот. Соответственно, на матрицу значений вероятностной карты заболоченности "накладывается" матрица карты спектрального индекса. Результат данного объединения представлен на фиг. 6.

В зависимости от значения обводненности определяется дискретная классификация болот, например, со следующими значениями:

- NDMI < 0.25 - слабая обводненность;
- 0.25 < NDMI < 0.45 - средняя обводненность;
- 0.45 < NDMI - сильная обводненность.

Таким образом, полученный результат объединения может быть интерпретирован как значения обводненности болот. На этапе постобработки может также выполняться определение контуров болот по заданному пороговому значению. То есть всем пикселям значение обводненности в которых превышает эмпирически подобранный порог, присваивается метка "болото", остальные пиксели получают метку "не-болото". Кроме того, все определенные заболоченные участки разделяются на три класса по эмпирически подобранным пороговым значениям: слабой обводненности, средней и сильной. Впрочем также возможна классификация болот на любое количество классов. Результаты данных операций представлены на фиг. 7 и 8.

Результатом работы являются

растровое изображение обводненности болот на исследуемой области: пиксели изображения принимают значения от 0 до 1, чем выше значение, тем более влажное болото (как показано на фиг. 7);

векторные контуры обнаруженных болот (как показано на фиг. 8);

при необходимости, вывод статистики заболоченности: общий процент заболоченной территории, а также процентное соотношение областей слабой, средней и сильной обводненности.

На финальном этапе формируются слои размеченных определенных алгоритмом объектов в общепринятых картографических форматах для применения результатов во внешних системах путем наложения бинарных масок объектов на карту местности. Пример такого финального результата приведен на фиг. 9.

Настоящее изобретение также позволяет определять, например, водные объекты на спутниковых снимках путем объединения вероятностной карты объектов и нормализованного разностного водного индекса NDWI, в данном случае каждому пикселю изображения присваиваются метки соответствующей категории, например метки "вода" или "остальное". Кроме того, благодаря настоящему изобретению возможно определение контуров леса и его анализа с целью разделения на лиственные и хвойные зоны. Для леса окрестности каждого пикселя важны, а для задачи разбиения леса на преимущественно лиственный и преимущественно хвойный распознавание наиболее эффективно производится по отдельным пикселям. Также для выполнения такой задачи требуется расчет модифицированного разностного водного индекса (mNDWI), а также использование зеленого канала (Green) и коротковолнового ближнего инфракрасного канала (обозначенный здесь как MIR). Ниже представлена формула для расчета модифицированного разностного водного индекса (mNDWI):

$$MNDWI = \frac{Green - MIR}{Green + MIR}$$

Изначально индекс mNDWI рассматривался для улучшения распознавания водных объектов. Однако авторами изобретения было обнаружено, что данный индекс полезен в том числе и для определения леса и его классификации путем объединения вероятностной карты объектов, вегетационного индекса NDVI и модифицированного разностного водного индекса mNDWI.

Кроме того, на спутниковых снимках могут быть определены, например, облачные участки путем объединения вероятностной карты объектов и карты нормализованного разностного водного индекса NDWI. Определение облачных участков на спутниковых снимках может быть использовано для удале-

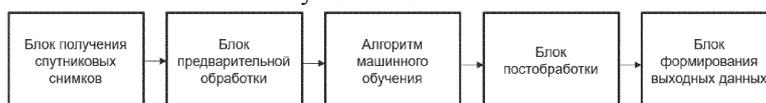
ния скрытых облаками участков и замены их участками той же местности, которые видны на другом спутниковом снимке, то есть для рода совмещения нескольких спутниковых снимков для получения карты местности без следов облачности.

Процесс реализации заявленной системы определения объектов на спутниковых снимках осуществляется аналогично способу, описанному выше.

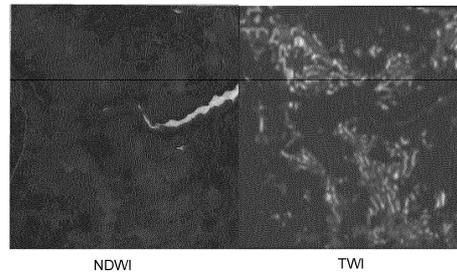
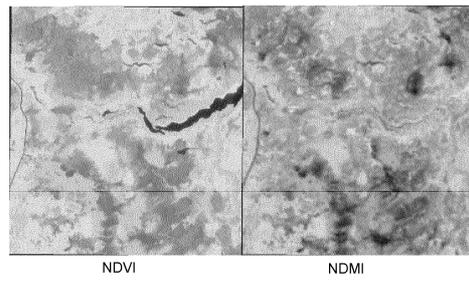
Таким образом, обеспечивается определение объектов разных видов и повышение эффективности и точности определения и анализа объектов на спутниковых снимках за счет более точной идентификации и последующей классификации, что позволяет, в свою очередь, получить более детальную информацию о местности без проведения полевых работ.

#### ФОРМУЛА ИЗОБРЕТЕНИЯ

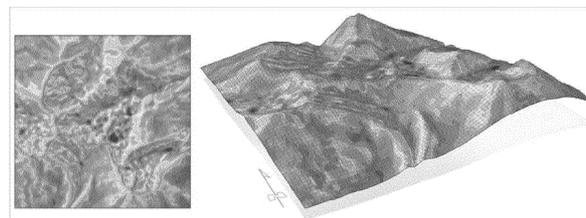
1. Способ определения объектов на спутниковых снимках, включающий в себя следующие этапы: получают спутниковые снимки, выполняют предварительную обработку спутниковых снимков, включающую, по меньшей мере, определение на основе спектральных каналов спутниковых снимков одного или более спектральных индексов, которые представляют в виде карты спектральных индексов, подают спектральные каналы и карту спектральных индексов в предварительно обученный алгоритм машинного обучения, получают вероятностную карту объектов с помощью алгоритма машинного обучения, выполняют постобработку вероятностной карты объектов, включающую удаление шумов и артефактов, восстановление пропущенных участков в вероятностной карте объектов, получают карту объектов путем объединения вероятностной карты объектов и карты одного или более спектральных индексов, формируют слои размеченных объектов, причем объектами определения являются болота, при этом для определения степени заболоченности дополнительно объединяют вероятностную карту объектов и карту топографического индекса влажности TWI, определенного на основании цифровой модели рельефа (ЦМР).
2. Способ по п.1, в котором в качестве алгоритма машинного обучения используют сверточную нейронную сеть.
3. Способ по п.1, в котором этап предварительной обработки также включает удаление шумов и артефактов и восстановление пропущенных участков в спутниковых снимках.
4. Способ по п.1, в котором болота определяют путем объединения вероятностной карты объектов, карты нормализованного разностного индекса влажности NDMI, карты нормализованного относительного вегетационного индекса NDVI и карты нормализованного разностного водного индекса NDWI.
5. Способ по п.1, в котором определяют один или более из следующих спектральных индексов: нормализованный относительный вегетационный индекс NDVI, нормализованный разностный индекс влажности NDMI, нормализованный разностный водный индекс NDWI, модифицированный разностный водный индекс mNDWI.
6. Способ по п.4, в котором дополнительно определяют по меньшей мере две степени обводненности болот, для чего формируют карту степени обводненности участков болот путем объединения вероятностной карты объектов и карты нормализованного разностного индекса влажности NDMI.
7. Способ по п.1, в котором объектами определения также являются леса, при этом их определяют путем объединения вероятностной карты объектов и карты нормализованного относительного вегетационного индекса NDVI.
8. Способ по п.7, в котором дополнительно для определения типа леса объединяют вероятностную карту объектов, карту нормализованного относительного вегетационного индекса NDVI и карту модифицированного разностного водного индекса mNDWI.
9. Способ по п.1, в котором объектами определения являются также водные участки, при этом их определяют путем объединения вероятностной карты объектов и карты нормализованного разностного водного индекса NDWI.
10. Система определения объектов на спутниковых снимках, содержащая по меньшей мере один процессор, оперативную память и машиночитаемые инструкции для выполнения способа определения объектов на спутниковых снимках по любому из пп.1-9.



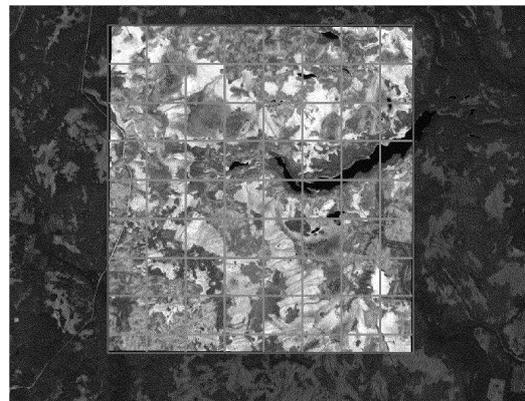
Фиг. 1



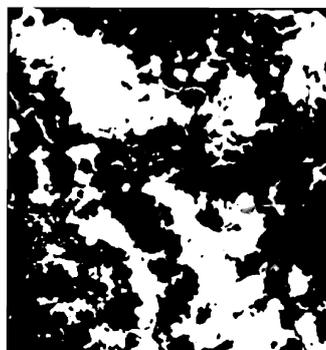
Фиг. 2



Фиг. 3



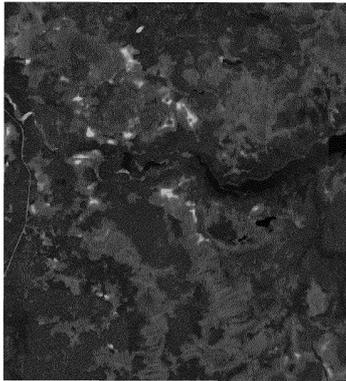
Фиг. 4



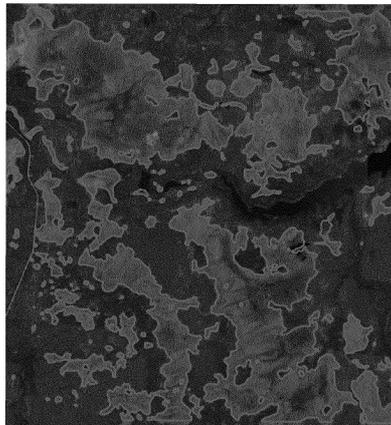
Фиг. 5



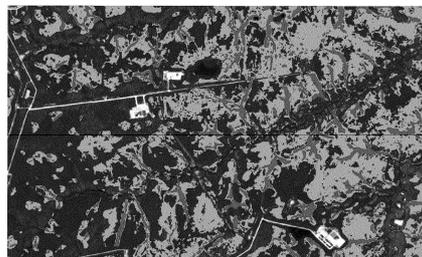
Фиг. 6



Фиг. 7



Фиг. 8



Фиг. 9

