

---

---

**МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ  
И ИНТЕРПРЕТАЦИИ КОСМИЧЕСКОЙ ИНФОРМАЦИИ**

---

---

**ПОСТРОЕНИЕ ТРЕХМЕРНЫХ МОДЕЛЕЙ РИГИДНЫХ ОБЪЕКТОВ  
ПО СПУТНИКОВЫМ ИЗОБРАЖЕНИЯМ ВЫСОКОГО  
ПРОСТРАНСТВЕННОГО РАЗРЕШЕНИЯ С ИСПОЛЬЗОВАНИЕМ  
СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ**

© 2020 г. **О. Г. Гвоздев<sup>a, c, \*</sup>, В. А. Козуб<sup>a, \*\*</sup>, Н. В. Кошелева<sup>a, \*\*\*</sup>,  
А. Б. Мурынин<sup>a, b, \*\*\*\*</sup>, А. А. Рихтер<sup>a, \*\*\*\*\*</sup>**

<sup>a</sup>Научно-исследовательский институт аэрокосмического мониторинга “АЭРОКОСМОС”, Москва, Россия

<sup>b</sup>Федеральный исследовательский центр “Информатика и управление” РАН, Москва, Россия

<sup>c</sup>ФГБОУ ВО “Московский государственный университет геодезии и картографии”, Москва, Россия

\*E-mail: gvozdev@miigaik.ru

\*\*E-mail: postbox-kozub@yandex.ru

\*\*\*E-mail: antipova@phystech.edu

\*\*\*\*E-mail: amurynin@bk.ru

\*\*\*\*\*E-mail: urfin17@yandex.ru

Поступила в редакцию 23.07.2020 г.

Описан метод построения трехмерных моделей ригидных объектов по одному спутниковому изображению, базирующийся на применении двух сверточных нейронных сетей, последовательно выполняющих обработку спутниковых изображений высокого разрешения. Первая нейронная сеть выполняет интегральный анализ изображения с целью сегментации и выделения объектов заданных физических классов. Вторая нейронная сеть выполняет локальный анализ изображения и работает с изображениями, сегментированными первой нейронной сетью в областях на изображении, предположительно содержащих объекты заданных классов. Описан алгоритм восстановления трехмерной модели объекта по растровым областям сегментированного изображения, полученного по результатам локального анализа, основанный на регрессионном анализе, оценке эквивалентных фигур, а также линейаризации и поляризации контуров. Приведены результаты работы алгоритма на примере объектов железнодорожной инфраструктуры. Показаны результаты построения трехмерных моделей трех объектов железнодорожной инфраструктуры, выявляемых по результатам работы нейронных сетей, по четырем информативным классам областей, таких как крыши, стены, рельсы, линии контактной сети (столбы). Стандартные размеры, такие как ширина железнодорожной колеи для российских железных дорог (1.52 м) и средняя высота железнодорожных столбов (11.35 м) используются для оценки масштабирующих коэффициентов, позволяющих получить оценки размеров основания и высоты объектов. Показана возможность построения 3D-моделей объектов различных площадей от 210 до 4200 м<sup>2</sup>.

*Ключевые слова:* спутниковые изображения, трехмерная модель, растровая область, искусственная нейронная сеть, сверточная сеть, машинное обучение, объекты инфраструктуры

**DOI:** 10.31857/S020596142005005X

## ВВЕДЕНИЕ

В связи с возрастанием экономической деятельности людей усложняется структура земной поверхности и населяющих ее объектов искусственного и естественного происхождения. Это приводит к необходимости разработки новых и совершенствования существующих неклассических цифровых методов для обработки большого объема космических изображений в действующих и создаваемых системах дистанционного мониторинга (в том числе многоспутниковых)

(Бондур, Савин, 1992; Савин, Бондур, 2000; Бондур, 2010).

Построение трехмерных моделей различных объектов на земной поверхности по спутниковым изображениям с использованием методов моделирования и синтеза изображений (Бондур, 2000а, б; Бондур, Савин, 1995; Бондур и др., 2003) важно для анализа динамических объектов, оценки ряда экономических характеристик. В частности, это целесообразно использовать при развитии способов эффективного управления пространственно-

распределенной геотехнической системой инфраструктуры железнодорожного транспорта на различных этапах жизненного цикла, включая: предпроектные изыскания; контроль хода строительных работ, включая оценку воздействия на прилегающую территорию; обеспечение перевозок, включая мониторинг потенциально опасных природных и техногенных воздействий на объекты инфраструктуры; обеспечение безопасности технологических процессов, ресурсосбережение; создание моделей пути и путевого развития станций; инвентаризация объектов земельно-имущественного комплекса; контроль несанкционированного использования полосы отвода и охранных зон; обеспечение антитеррористических мероприятий; обеспечение ситуационной осведомленности при чрезвычайных ситуациях; экологический контроль воздействия объектов железнодорожного транспорта на окружающую среду.

С учетом необходимости оперативной обработки больших потоков данных, для построения трехмерных моделей интересующих нас объектов требуется решить две основные задачи: задачи определения места расположения объекта на спутниковом изображении, связанной с сегментацией этого изображения по определенному принципу, и задачи нахождения информативных признаков, необходимых собственно для построения трехмерной модели объекта.

Разработка алгоритмов автоматического выделения и сегментации объектов естественного и антропогенного происхождения является одной из важнейших задач обработки спутниковых изображений. Методы решения этой задачи успешно развиваются в последние годы применительно к различным классам объектов: растительность и почва (Бондур, 2014, 2015; Бондур и др., 2016а; Бондур, Чимитдоржиев, 2008а, б), объекты, процессы и явления на поверхности океана (Бондур, Зубков, 2005; Бондур и др., 2006, 2012; Bondur, 2005, 2011). свалки и мусорный покров (Рихтер и др., 2015; Казарян и др., 2016; Казарян и др., 2017; Казарян и др., 2018а, б; Гвоздев и др., 2019; Казарян и др., 2018а, б; Мурынин и др., 2018; Richter, 2019), импактные районы (Бондур, Воробьев, 2015; Бондур и др., 2016б).

Сегментация спутниковых изображений объектов естественной природы, таких как, например, типы почвы или растительность определенного типа, возможна с применением методов, оперирующих спектральными яркостями отдельных пикселей, определяемых фитоценологическими, гумификационными и другими механизмами гомеостаза этих объектов (Бондур, 2014; Бондур, Старченков, 2001; Бондур, Воробьев, 2015; Бондур и др., 2016а; Мурынин и др., 2019; Richter

et al., 2017; Kazaryan et al., 2017; Shakhramanyan et al., 2017).

Иначе обстоит дело с различными искусственными объектами: домами, железными и автомобильными дорогами, элементами городской, сельской и транспортной инфраструктуры и другими. Эти объекты могут иметь различные спектральные параметры и зачастую не позволяют ограничиться методами, работающими с каждым пикселем изображения в отдельности (Бондур, 2014). При этом информация о таких объектах важна для анализа дорожной сети, моделирования и прогнозирования чрезвычайных ситуаций, актуализации геоинформационных данных (Бондур, 2000а, б; Кудряшов, Соловьев, 2019).

В данной статье проведем краткий обзор основных методов построения трехмерных моделей ригидных объектов на примере объектов железнодорожной инфраструктуры и опишем метод интеллектуальной обработки спутниковых изображений, основанный на многомасштабном анализе изображений с применением искусственных нейронных сетей (ИНС) и с последующей векторизацией растровых изображений с использованием методов регрессионного анализа.

#### СУЩЕСТВУЮЩИЕ МЕТОДЫ ПОСТРОЕНИЯ ТРЕХМЕРНЫХ МОДЕЛЕЙ ОБЪЕКТОВ ЗЕМНОЙ ПОВЕРХНОСТИ

Современные подходы к извлечению трехмерной информации с изображений местности можно условно разделить на традиционные методы, основанные на классических подходах к обработке изображений, и нейросетевые методы, основанные на интеллектуальном анализе данных. Традиционные методы извлечения трехмерной информации из двумерных изображений основаны на использовании стереопар изображений и построении по ним карт диспаратности (Fua, 1991; Матвеев, Мурынин, 2003). Для вычисления карт диспаратности при автоматической и автоматизированной обработке стереопар изображений в настоящее время разработаны эффективные алгоритмы и быстродействующие прикладные программы, обзор которых изложен, в частности, в работе (Hamzah, Ibrahim, 2015). Метод успешно применяется при обработке стереопар спутниковых изображений для построения трехмерных карт поверхностей и карт застройки (Alobeid et al., 2010; Hirschmüller, 2008; Abdulmuila, 2015).

Поскольку получение стереопар космических изображений трудоемко и относительно дорого, активно развиваются методы извлечения 3D-информации из одиночных спутниковых изображе-

ний, которые предполагают как привлечение вспомогательных данных, так и дополнительную операторскую обработку данных спутниковой съемки (Abduelmula, 2015; Мурынин, Рихтер, 2018; Рихтер и др., 2018; Казарян и др., 2018в; Шахрамьян и др., 2018а, б).

В последнее время интенсивно развиваются нейросетевые методы, основанные на машинном обучении и работающие по одному изображению (Umut Gunes Sefercik et al., 2014; Sherrie Wang et al., 2020; Srivastava et al., 2017; Ghamisi, Yokoya, 2018; Mou et al., 2018; Amirkolaei, Arefi, 2019; Bittner et al., 2018; Kaiser et al., 2017). Одна из групп нейросетевых методов решает задачу высокоточной локализации объектов на изображении и их классификации с помощью ИНС, которая чаще всего упоминается под названием сегментация образца (instance segmentation) (Гвоздев и др., 2020).

В последние годы для задач обработки изображений стандартом фактически стали сверточные ИНС (CNN), которые позволяют учитывать контекст и после 2012 г. неизменно занимают первые места среди алгоритмов сегментации и классификации изображений.

Приведем наиболее характерные методы построения трехмерных моделей зданий как наиболее распространенной категории искусственных объектов земной поверхности.

Среди традиционных методов, не использующих ИНС, можно отметить:

1. Метод для определения формы крыши, состоящий в сравнении спектров матрицы смежности и требующий предварительного выделения и векторизации линий крыш (с помощью преобразований Хафа). Методом распознаются только заранее установленные классы крыш, а для полного восстановления 3D-модели зданий (до степени детализации LoD2) авторы предлагают дополнительно использовать карту высот (Тужилкин, 2015);

2. Метод сегментирования зданий, основанный на анализе спектральной гистограммы, на которой выделяются пики яркостей, относимые к точкам здания. Предварительно по данным ГИС позиционируются рецептивные участки изображения (с большой вероятностью расположения здания). Для уменьшения ошибок привлекается дополнительная верификация с использованием теневых, геометрических и размерных признаков (Соколова, 2015);

3. Метод построения 3D-моделей зданий по топографическим планам, созданным и редактируемым для многих частей РФ. На топопланах отмечены дома и их высоты. На первом этапе волновым методом автоматически выделяются контуры

домов по изображениям топопланов. После — строится его 3D-модель, помещаемая на нужное географическое место. Для окрашивания стен используются наземные фотографии зданий с разных ракурсов. Также авторы предлагают пользовательское приложение, которое должно реализовать предложенный ими алгоритм в удобной форме (Кудряшов, Соловьев, 2019).

В последние годы интенсивно развиваются нейросетевые методы извлечения 3D-информации об объектах из одиночных спутниковых изображений:

1. Обучение нейронной сети (DeepResUnet), позволяющее с высокой точностью различать дома на изображениях сверхвысокого разрешения. Данная сеть использует сверточную структуру с остаточными связями и в работе обучается с нуля. Позволяет с точностью выше 90% классифицировать каждый пиксель изображения на один из двух классов: здание или не здание. Для обучения сети был создан новый датасет, основанный на свободно распространяемых снимках с сайта (Yaning et al., 2019);

2. Обучение сверточной сети на основе VGG для различения дороги и здания, на базе большого количества открытых данных (Google maps, Open street maps), дающее высокое пространственное расхождение датасетов, но приемлемое качество сегментации (примерно 85%) (Persello, Stein, 2017);

3. Предложение архитектуры сверточной сети, базирующейся на архитектуре Mask R-CNN. Основная доработка заключается в улучшении рецептивного блока, генерирующего прямоугольные области, которые могут иметь угол наклона (в отличие от классической структуры, где их стороны параллельны граням изображения) (Wen et al., 2019);

4. Построение 3D-моделей зданий, задействующее две нейросети и большое количество метрик качества. Первая ИНС — для определения линий крыш, должна выделять три различных типа: карнизы (краевые линии крыши), коньки (гребни) и линии, которые соединяют карнизы и коньки (hip lines). Вторая — для восстановления карты высот, обучалась по данным лидара. Алгоритм в автоматическом режиме определяет линии крыши, воссоздает по ним конструкцию крыши, принадлежащую к одному из 11 предустановленных классов, затем комплексирует их данными лидара о высоте (ввиду преимущества спутниковой съемки в надири) (Fatemeh Alidoost et al., 2019);

5. Распознавание формы основания и крыши, задействующее две предобученные сети, основанные на архитектуре VGG. Для их обучения специально строились датасеты, для которых была проведена аугментация (вращения и цветовые

искажения). Сначала, с помощью селективного поиска отбираются области интереса, а уже затем к ним последовательно применяются две нейронные сети. Первая устанавливает рецептивную область, вторая пытается предсказать тип крыши: плоская, двухскатная или вальмовая (hip-roof) (Fatemeh Alidoost, Hossein Arefi, 2018).

6. Дополнительное использование лидаров позволяет получать наиболее информативные модели зданий, включающие не только форму и габариты, но также и определение окон, разделение сколекса зданий на отдельные части, разделение здания по этажам (Sun et al., 2018);

### ВЫБОР АРХИТЕКТУРЫ ПРЕДЛАГАЕМОГО МЕТОДА

Предлагаемый метод построения трехмерных моделей объектов земной поверхности основан на многомасштабном подходе и предполагает, что исходные данные были предварительно обработаны методом повышения разрешения, отличающимся репрезентативным понижением разрешения изображений обучающей выборки.

Реализация предлагаемого метода включает два этапа обработки спутниковых изображений.

На первом этапе выполняется интегральный анализ изображения, целью которого является выявление основных свойств и соотношений объектов на изображении:

– Принадлежность объектов тематическим классам: здания, сооружения, ограждения, железнодорожные пути и др.;

– Принадлежность пикселей пространственным классам: крыши и стены зданий, поверхность земли;

– Принадлежность пикселей теням от объектов;

– Принадлежность пикселей значимой окрестности объектов;

– Группировка пикселей изображения в объекты и извлечение релевантной им информации (значимого контекста).

На втором этапе проводится индивидуальный (локальный) анализ каждого выявленного объекта, целью которого является построение его трехмерной модели. Этот этап основывается на использовании результатов первого этапа, в зависимости от которых объект подвергается различным процедурам обработки:

– уникальные объекты (определяются по заранее известным пространственным положениям) не подвергаются обработке, при наличии – используются готовые 3D-модели;

– типовые объекты (определяются по тематическому классу объекта, определенному на этапе интегрального анализа), подвергаются специализированной (для данного типа объектов) процедуре определения свойств;

– для остальных объектов выполняется процедура восстановления геометрии.

Третий случай, очевидно, является наиболее сложным и имеет, в свою очередь, два подэтапа: 1) извлечение геометрических признаков (граней крыши и стен) с помощью сверточной ИНС; 2) интерпретация полученных геометрических признаков.

Сверточная ИНС извлечения геометрических признаков аналогична по своей структуре ИНС интегрального анализа, за исключением выходной группы, специализированной для высокоточной локализации линейных и точечных объектов путем применения FocalLoss (Tsung-Yi Lin et al., 2018).

Из результатов выполнения интегрального и локального анализа формируется единый информационный продукт, включающий все значимые промежуточные и окончательные результаты, пригодный для дальнейшей машинной или ручной обработки.

Принципиальная схема метода представлена на рис. 1.

I. Обнаружение и локализация площадных, линейных и точечных объектов.

В разработанном методе значительную роль играет решение задачи обнаружения и локализации множеств площадных, линейных и точечных объектов.

Проблематика их обнаружения с применением искусственных нейронных сетей заключается в отсутствии однозначно-оптимального метода построения нейросетевых моделей, возвращающих множество равноправных объектов переменной длины при сегментации образца.

Наиболее развитым в решении задачи сегментации образцов является семейство методов “Region Proposal Networks” (Kaiming He et al., 2018; Shaoqing Ren et al., 2016; Joseph Redmon et al., 2016). Их основой является генерация множества кандидатов объектов с их последующей фильтрацией и уточнением, которая, в свою очередь, может выполняться с помощью дополнительной нейросетевой модели. Кандидаты объектов представляются в виде параметров априорно определенных опорных точек на изображении. Исходное расположение этих опорных точек является компромиссным параметром: их высокая плотность понижает общую производительность схемы и увеличивает шансы ложных срабатыва-

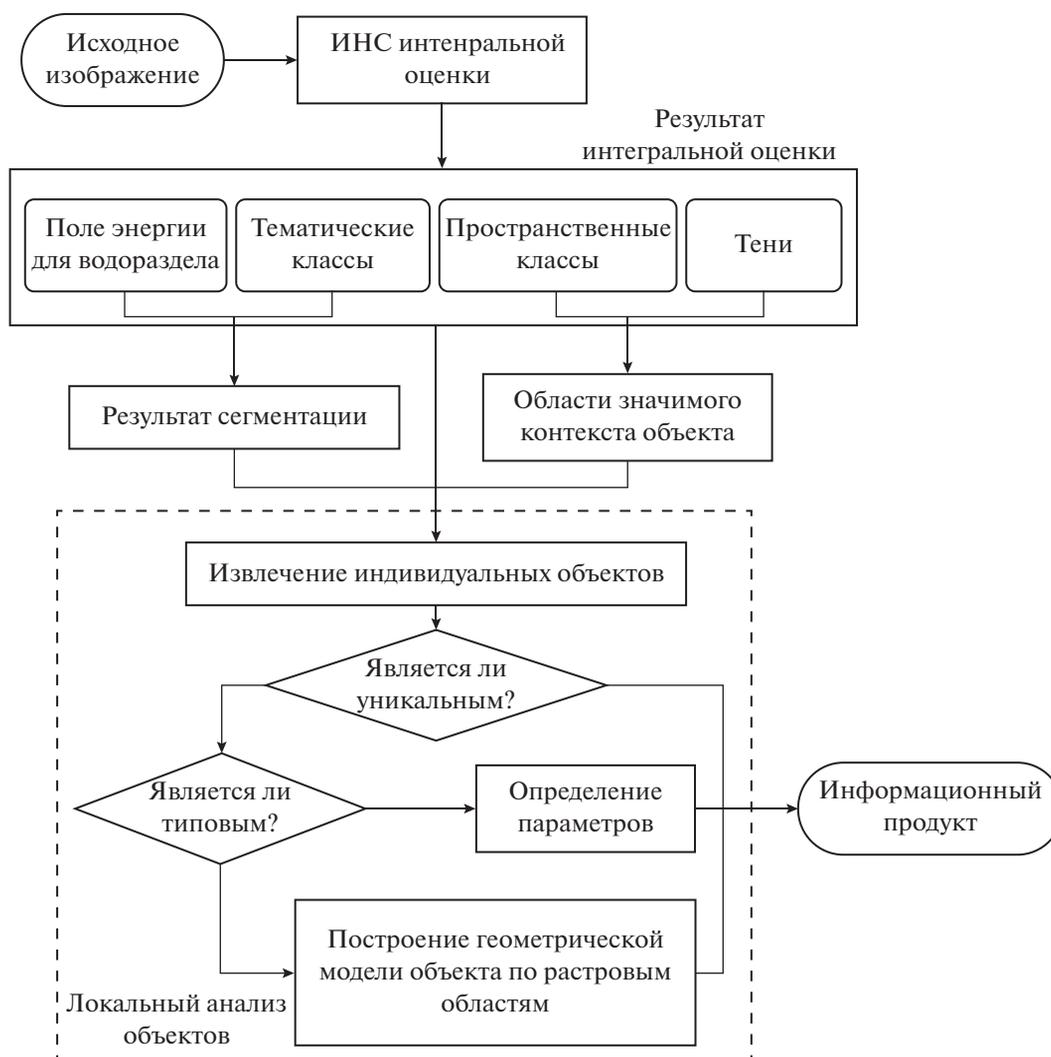


Рис. 1. Принципиальная схема разработанного метода.

ний, в том время как низкая приводит к неспособности обнаружения схемой мелких тесно расположенных объектов.

Альтернативный класс методов сегментации образцов основан на введении в модель промежуточного состояния. Например – координат отправной точки для поиска объекта (Konstantin Sofiiuk et al., 2019) или задействования рекуррентных нейросетевых топологий (Amaia Salvador et al., 2019).

Несмотря на высокую степень изученности, оба эти класса обладают существенным с точки зрения решаемой задачи недостатком: они ограничены обнаружением крупных площадных объектов и не могут быть адаптированы для применения к линейным или точечным объектам.

Для преодоления этого противоречия авторами предлагается обратиться к еще одному классу методов сегментации образцов, основанному на

генерации выходных данных в форме, тривиально обрабатываемой классическими методами, способных к обработке переменного количества объектов. Среди них можно отметить методы, основанные на концепции instance embedding: присвоении каждому пикселу изображения координат в признаковом пространстве, в котором тривиальной является кластеризация (Bert De Brabandere et al., 2017). Другим подходом является генерация полей “энергии” для дальнейшего использования в методе “водораздела” (Min Bai Raquel Urtasun, 2017).

В настоящей работе использован именно этот метод с обобщением обучаемых в его рамках нейросетевых моделей для аппроксимации полей “энергии” не только для площадных, но линейных и точечных объектов. При этом для площадных объектов “энергия” определяется как мера близости к центру объекта, в то время как в точеч-

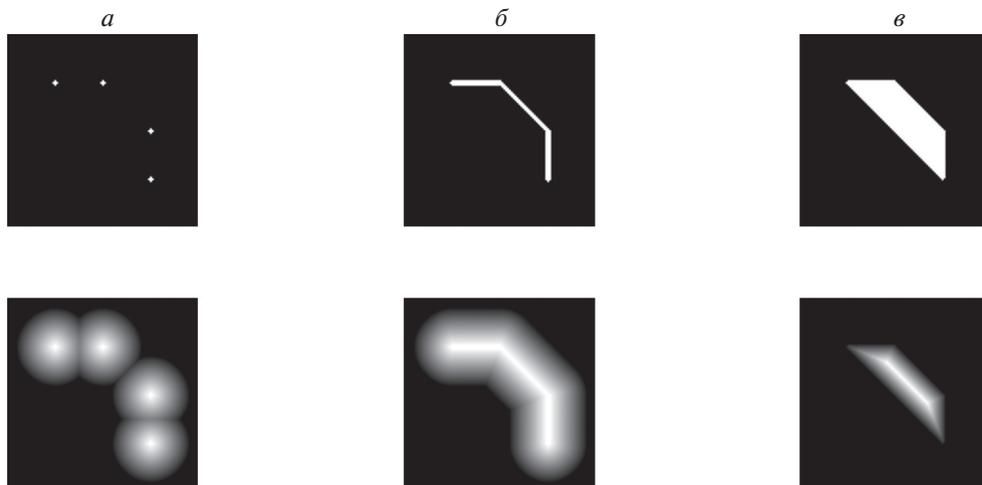


Рис. 2. Примеры аппроксимируемых нейросетевой моделью полей энергии для точечных (а), линейных (б) и площадных (в) объектов.

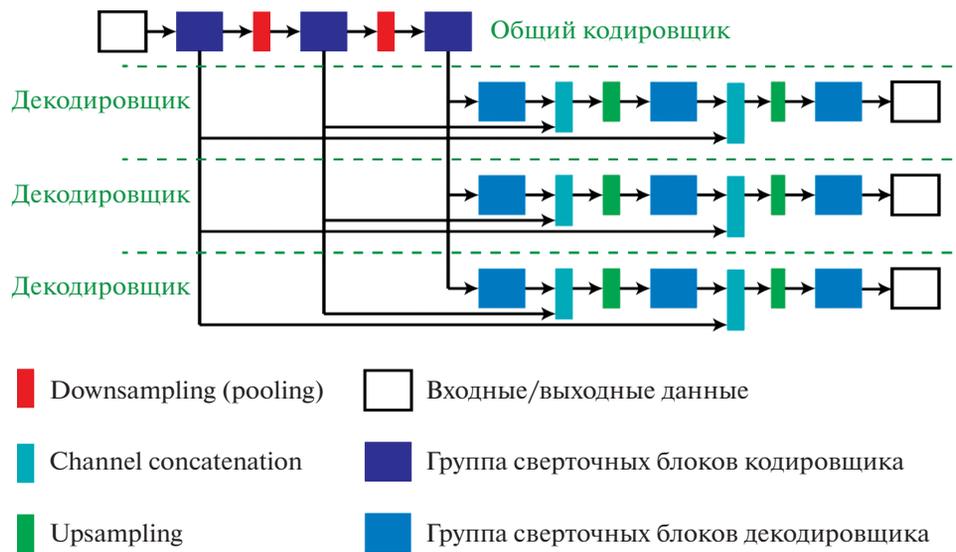


Рис. 3. Принципиальная схема топологии нейросетевой модели на базе U-Net с несколькими декодировщиками.

ных и линейных случаях – как мера близости к ближайшей точке объекта.

Локализация точечных и линейных объектов, таким образом, сводится к поиску локальных максимумов (рис. 2).

## II. Модель интегрального анализа.

Для интегрального анализа применяется модель на основе ИНС. В рамках данной задачи наиболее важно обеспечить пиксельную точность локализации и классификации объектов, а также аппроксимации полей “энергии” для применения водораздельных методов, что успешно обес-

печивают нейросетевые топологии семантической сегментации.

В рамках данного метода используется топология на основе U-Net (Olaf Ronneberger et al., 2015), расширенная и дополненная авторами для задач интерпретации аэрокосмических изображений.

Ввиду необходимости решения нескольких задач в рамках одной модели, для сокращения времени обучения и обеспечения консистентности результатов вместо ансамбля независимо обучаемых моделей, используемого традиционно, авторами применены следующие модификации топологии нейросетевой модели и процесса ее обучения:



Рис. 4. Алгоритм построения геометрической модели объекта по растровым областям.

- 1) Блок кодировщика оставлен без изменений;
- 2) Для каждой из подзадач реализованы отдельные блоки декодеровщика и функции потерь;
- 3) В целях оптимизации потребления оперативной памяти в процессе обучения модели для каждого из декодеровщиков выполняется отдельная операция градиентного спуска.

Принципиальная схема предлагаемой топологии представлена на рис. 3.

III. Модели индивидуального (локального) анализа.

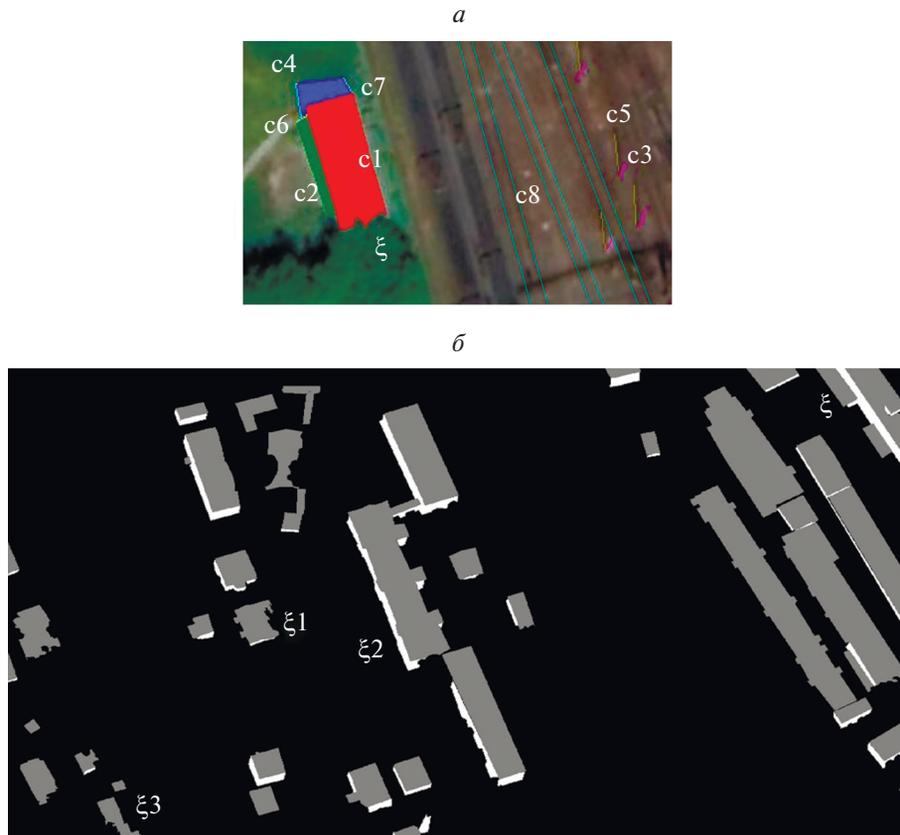
Предлагаемый авторами метод предполагает разработку отдельных нейросетевых моделей для каждого укрупненного класса объектов, в частности: модель классификации типов вагонов; модель определения параметров типовых зданий; модель выделения геометрических признаков нетиповых зданий.

С точки зрения топологии нейросетевых моделей данные задачи могут быть сведены к двум: задача извлечения количественных признаков из изображений и задача локализации элементарных геометрических примитивов. Первая из них, в свою очередь, сводится к классической задаче аппроксимации детерминированного набора свойств объекта (Arsalan Mousavian et al., 2015). Вторая – к

решению, предложенному в качестве основы для построения модели интегрального анализа.

#### АЛГОРИТМ ПОСТРОЕНИЯ ТРЕХМЕРНОЙ ГЕОМЕТРИЧЕСКОЙ МОДЕЛИ ОБЪЕКТА ПО РАСТРОВЫМ ОБЛАСТЯМ

На рис. 4 приведена общая схема алгоритма автоматизированного построения трехмерных моделей объектов железнодорожного транспорта (зданий) по растрам классов  $c_1$ ,  $c_2$  и  $c_8$ . Применяемый подход имеет следующие особенности: 1) Восстановление формы объекта проводится по одному ортотрансформированному спутниковому изображению; 2) Метаданные изображения не используются; 3) Привлекается дополнительная входная информация – размеры эталонных стандартизированных объектов; 4) Детектируемые растры классов непрерывны, могут иметь произвольную форму, в том числе с наличием пустот; 5) Для полных объектов (известны растры крыши и стен) восстанавливается 3D-модель; 6) Для неполных объектов (известны растры крыши или стен) оценивается 2D-модель; 7) Для объектов, частично скрытых: в рамках снимка (заслонение фоновыми объектами) или за рамками снимка – оценивается только видимая часть; 8) Для частично скрытых объектов скрытая часть может



**Рис. 5.** Пример сегментации изображения объектов железнодорожной инфраструктуры: *a* – информативные классы; *б* – сегментированное изображение – выделены крыши и стены.

быть восстановлена с учетом предположения их формы.

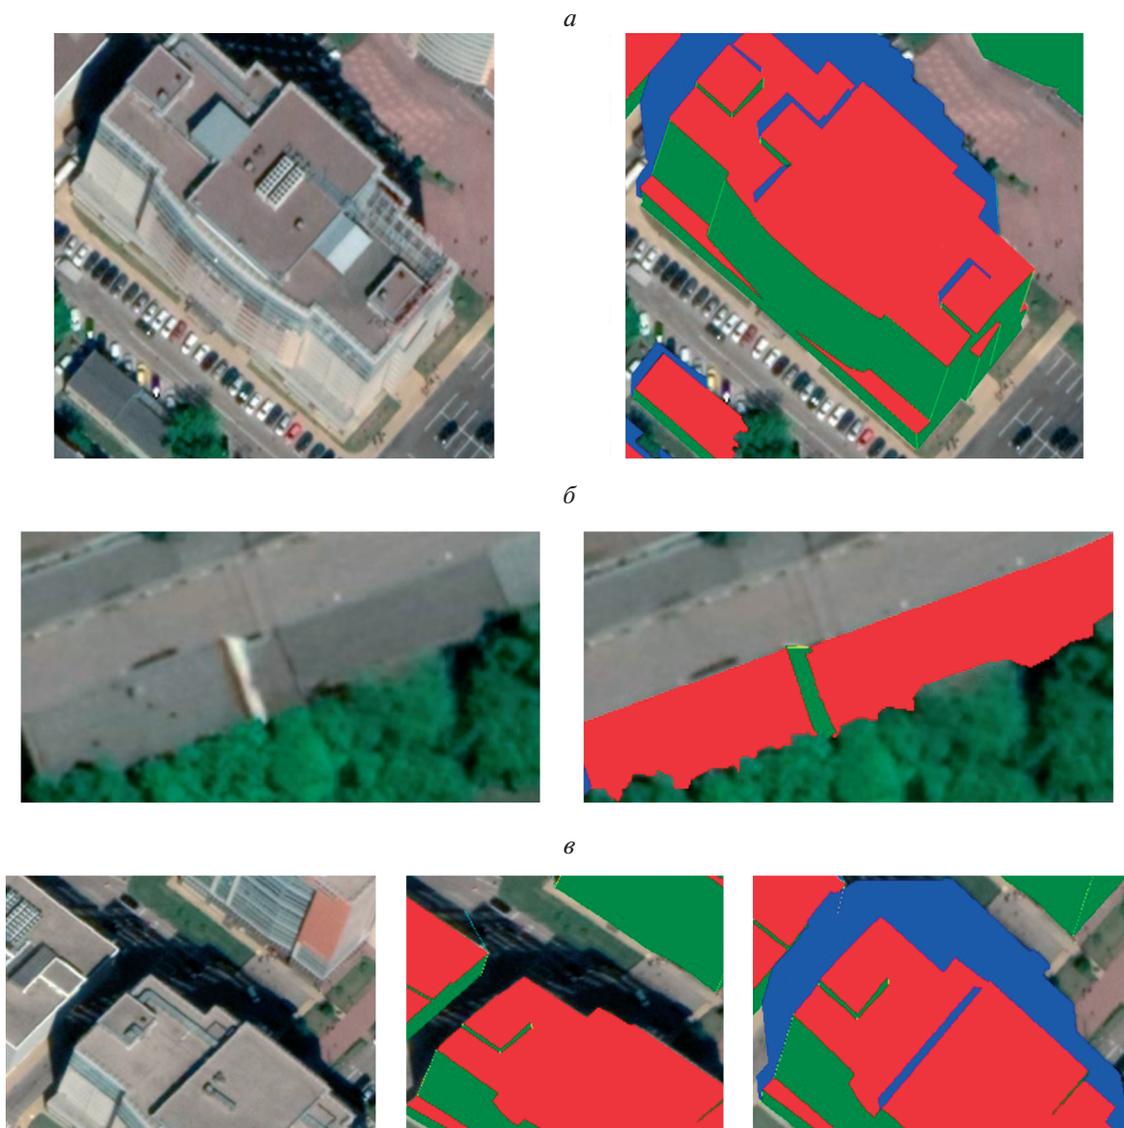
#### ПРИМЕР ПОСТРОЕНИЯ ГЕОМЕТРИЧЕСКОЙ МОДЕЛИ ОБЪЕКТА ПО РАСТРОВЫМ ОБЛАСТЯМ

Приведем пример использования разработанного алгоритма. В примере выбраны следующие информативные классы элементов жестких объектов (рис. 5):  $c_1$  – крыша;  $c_2$  – стена здания;  $c_3$  – вертикальная составляющая опорного столба;  $c_4$  – тени от  $c_1$  и  $c_2$ ;  $c_5$  – тени от  $c_3$ ;  $c_6$  – направляющая  $c_2$ ;  $c_7$  – направляющая  $c_4$ ;  $c_8$  – рельсы. Классы  $c_1$ ,  $c_2$ ,  $c_4$  размечаются как полигоны, классы  $c_3$ ,  $c_4$ ,  $c_6$ ,  $c_7$ ,  $c_8$  – как полилинии.

Растровые области классов жестких объектов в наборе данных имеют ряд особенностей, затрудняющих применение традиционных методов тематической обработки для восстановления их трехмерных моделей. К ним относятся (рис. 6): 1) Возможное наличие надстроек и пристроек к зданию, подобных ему по форме и возможно имеющих также свои надстройки и пристройки (рис. 6, *a*);

2) Слипание или пересечение областей, относимых к разным объектам (крыш, стен, теней) (рис. 6, *a*); 3) Заслонение областей одних информативных классов (видимость ниже) областями других информативных классов (более открытых, видимость выше) или фоновыми объектами (например, деревья или тени скрывают часть крыши или стены здания) (рис. 6, *б*); 4) Искажение тени от объекта при ее падении на неровную поверхность (рис. 6, *в*). Так, (3) приводит к: 1) Разрыву одной связной области на несколько, которые могут принадлежать одному объекту; 2) Имплицитности образа объекта за счет покрытия растром только части объекта и его неоднозначной интерпретации; 3) Стохастической форме границы, встречаемости или полному отсутствию прямых линий границы. В сочетании с другими обструкционными особенностями качество раstra области для построения по ней 3D-модели еще более неблагоприятно.

При расчетах были использованы следующие эталонные размеры:  $a = 1.52$  м – расстояние между рельсами, класс  $c_8$ .  $b = 11.35$  м – высота железнодорожного столба (промежуточные опоры с нормальным габаритом на двухпутном



**Рис. 6.** Особенности построения обучающей выборки (на примере изображений): *a* – наличие надстроек и пристроек, слипание и пересечение областей, относимых к разным объектам; *б* – заслонение областей одних информативных классов областями других информативных классов или фоновыми объектами; *в* – искажение тени от объекта при ее падении на неровную поверхность.

участке), класс  $c_3$ . По ним найдены масштабирующие коэффициенты  $m_i = R_i/r_i$ ,  $i = 1...q$  по направлениям  $\bar{n}_i = \bar{r}_i/r_i$ , где отрезки  $r_i$  – меряются координатами точек на изображении  $I$ ,  $R_i$  – соответствующие линейные размеры отрезков. В нашем случае  $q = 4$ :  $\bar{n}_1$  и  $\bar{n}_2$  – направления вдоль прямоугольных стен здания (предполагаем здания прямоугольными), характерные для каждого объекта,  $\bar{n}_3$  и  $\bar{n}_4$  – вертикальное направление и направление падения тени, характерные для снимка в целом. Считаем, что  $\bar{r}_3 = \overline{AC}$ ,  $\bar{r}_4 = \overline{BC}$ ,  $m_1 = m_2 = m = a/r$ ,  $r = DE$ ,  $R_3 = R_4 = b$ , где  $m$  – пространственное разрешение. Столбы  $AC$ , их тени  $BC$ , расстояние меж-

ду рельсами  $DE$  меряются для соответствующих выборок объектов и находятся как средние значения этих выборок (рис. 7, *a*).

Алгоритм включает два этапа обработки спутникового изображения.

На первом этапе проводилась постобработка классификационного изображения  $K$  (см. рис. 7, *б*).

1. Выделение классов  $c_1$  ( $i = 1$ ) и  $c_2$  ( $i = 2$ ):

$$K_i(x, y) = \begin{cases} 1, & (x, y) \in c_i \\ 0, & (x, y) \notin c_i \end{cases}$$
, заполнение “пустот”, при необходимости эрозия (для разделения “слипшихся” объектов) и дилатация при выделении каждого объекта в отдельности.

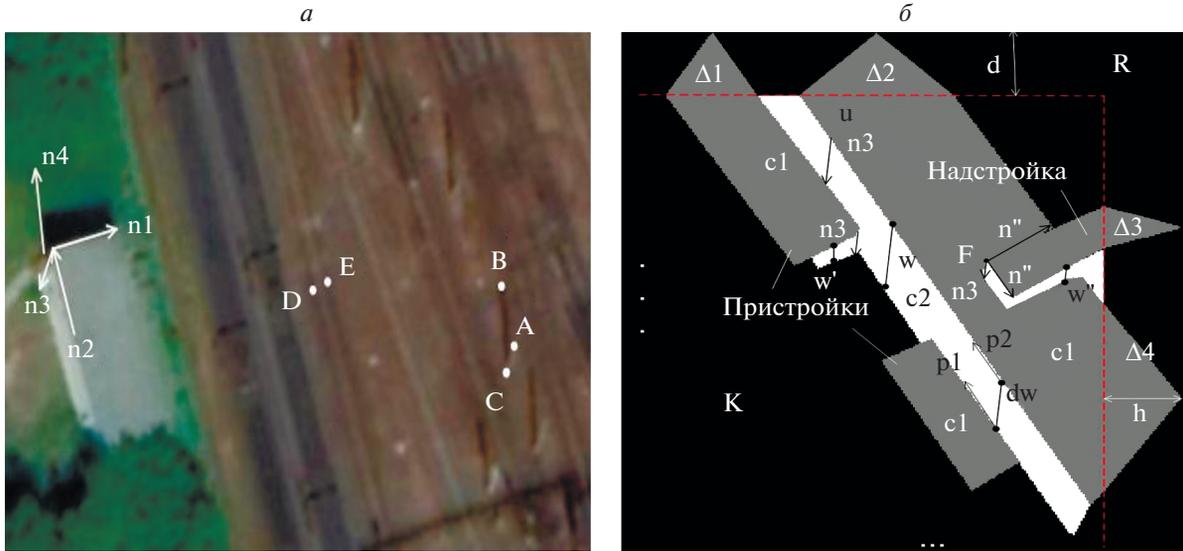


Рис. 7. Основные построения: а – входное изображение; б – участок классификационного изображения (объект ξ).

2. Построение матриц  $K'_1 = K_1 + R + \sum_{j=1}^p \Delta_j$ ,  $K'_2 = K_2 + R$ , где  $R$  – “пустая” рамка некоторой толщины  $d$  (задает долю скрытой части объекта за рамками изображения от всего объекта),  $\Delta_j$  – добавляемые фигуры высотой  $h < d$  с основаниями на границах рамки и объектов (за них принимаются равнобедренные треугольники).

3. Выделение объектов в  $K'_1$  и  $K'_2$  и их соотнесение: поиск стен, смежных с крышей и лежащих “на пути” вектора  $\bar{n}_3$  от границы крыши; поиск пристроек – другая крыша, прерывающая стену “на пути”  $\bar{n}_3$ , вместе с ее стенами; поиск надстроек – часть той же крыши, ограниченная отрезками от углов  $F$  по направлениям  $\bar{n}'$ , таким что  $\bar{n}' \perp \bar{n}''$ ,  $\angle(\bar{n}', \bar{n}_3) = \max$ .

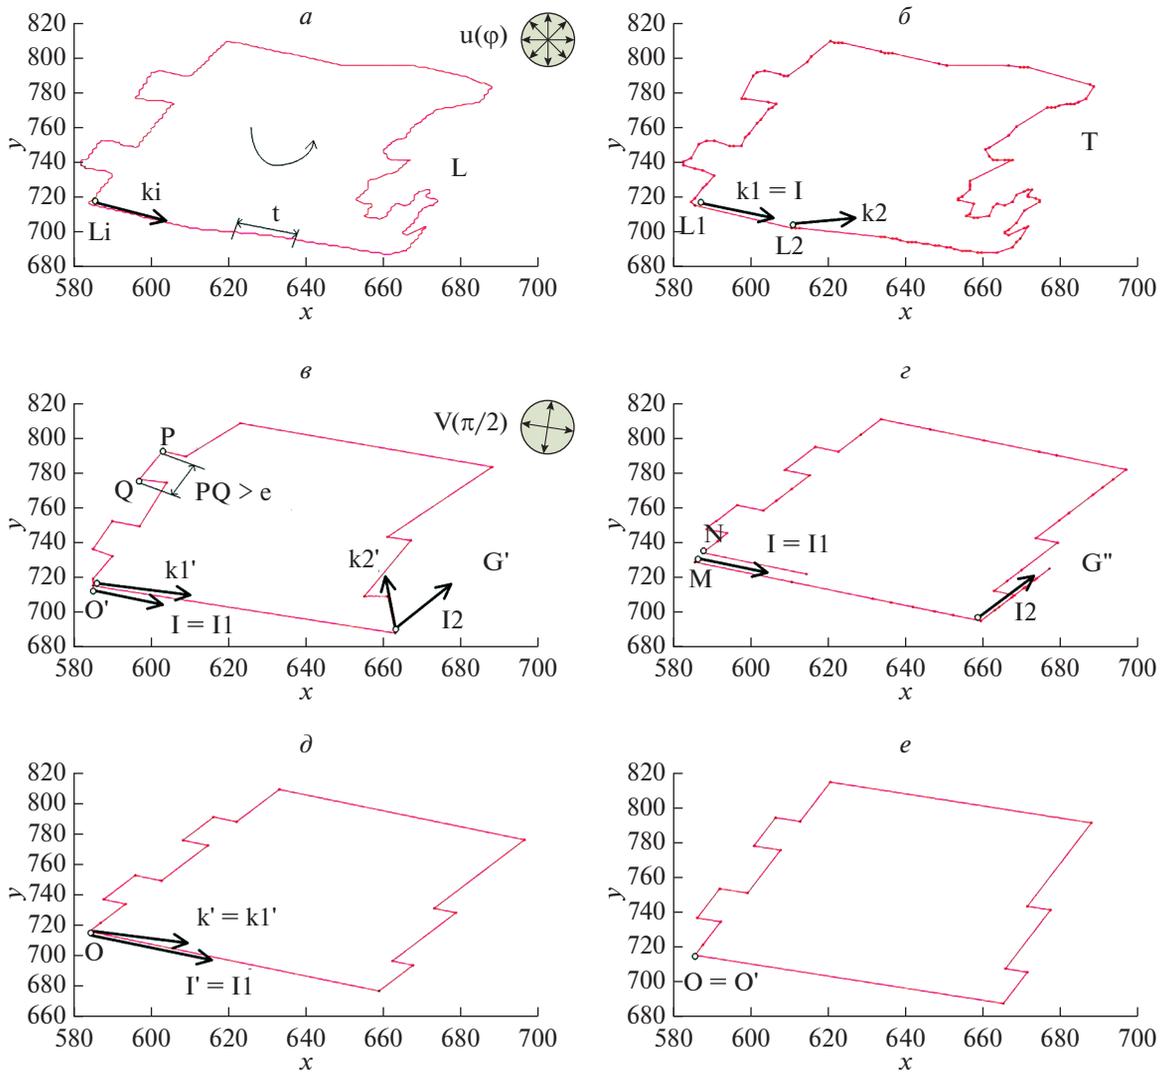
На втором этапе проводилась автоматизированная обработка каждого объекта в отдельности (рис. 8):

1. Выделение и отслеживание контура (получение линии контура  $L$ ).

2. При линейаризации для каждой точки  $L_i = (x_i, y_i)$  линии  $L$  крыши находился отрезок линии регрессии точки  $L_i$  и последующих  $t$  точек ( $t$  – линейный шаг линейаризации). Далее направляющие отрезков поворачиваются до ближайших направлений  $\bar{k}_i \in u$ , где  $u$  – множество углов от 0 до  $2\pi$  с некоторым шагом  $\varphi$  ( $\varphi$  – угловой шаг линейаризации). Находится линейаризованная линия  $T$  – точек линии  $L$ , для которых меняется направление  $\bar{k}_i$ .

3. При поляризации в плоскости направляющие  $\bar{k}_j$  отрезков линии  $T$  поворачиваются до ближайших направлений  $\bar{l}_j \in v$ , где  $v$  – множество ортогональных направлений от  $\bar{l}$  ( $\bar{n}_1 = \bar{l}, \bar{n}_2 \perp \bar{n}_1, -\bar{n}_1, -\bar{n}_2$ ). За  $\bar{l}$  принимается направление отрезка линии  $T$ , составляющего наиболее прямой и длинный участок  $L$ , при отсутствии таких участков за  $\bar{l}$  принимается направление эквивалентного эллипса точек  $T$ . Строится опорная линия  $G'$  – точек линии  $T$ , для которых меняется направление  $\bar{l}_j$ , а длины отрезков от этих точек больше некоторого  $e$ . Ей соответствует поляризованная линия  $G''$ , состоящая из отрезков длин  $G'$ , но в поляризованных направлениях  $\bar{l}_j$ . При доведении  $G$  линия  $G''$  замыкается в начальной  $M$  и одной из последних  $N$  точках в одном из направлений  $\bar{l}_j$  и удаляются точки, в которых направление не меняется на ортогональное.

4. При геометрической коррекции линии  $G$  относительно линии  $L$ :  $G$  сдвигается из точки  $O'$  в точку  $O$ , затем поворачивается от направления  $\bar{l}'$  до направления  $\bar{k}'$  и масштабируется в  $s_x$  и  $s_y$  раз по оси абсцисс и ординат относительно точки  $O$ . За точки  $O$  и  $O'$  принимаются начало наиболее длинного отрезка линии  $G$  и соответствующей ему точки линии  $G'$  либо геометрические центры  $G$  и  $G'$ . За  $\bar{k}'$  и  $\bar{l}'$  принимаются направления этих отрезков либо ближайшие друг к другу направления эквивалентного эллипса.  $s_x$  и  $s_y$  – отношения по оси абсцисс и ординат расстояния от  $O$  до самой дальней от нее точки (на линии  $G'$ ) к рассто-



**Рис. 8.** Основные построения (второй этап обработки, на примере объекта  $\xi_1$ ): а – линия контура; б – линейризованная линия; в – опорная линия; г – поляризованная линия; д – доведение; е – геометрическая коррекция.

янию от  $O'$  до самой дальней от нее точки (на линии  $G$ ).

Присоединение пристройки или надстройки к объекту осуществляется присоединением ее крыши к крыше объекта сдвигом и поворотом от вектора  $p_1$  до вектора  $p_2$ .

5. Высота  $H$  объекта оценивается как среднее значение длин отрезков  $w$ , соединяющих точки границы крыши по направлению  $\bar{n}_3$ , пересекающих точки смежной с крышей стены до окончания стены (см. рис. 7). Превышения пристроек  $H'$  оцениваются как средние  $w'$  (при наличии стен пристроек) либо как разности  $w - dw$  (при отсутствии стен пристроек). Превышения надстроек  $H''$  оцениваются как средние значения отрезков

$w''$ , соединяющих точки границ крыши вдоль  $\bar{n}_3$  и пересекающих точки смежной с крышей стены.

Форма крыши оценивается по разностям  $h = w - H$  ( $h' = w' - H'$ ,  $h'' = w'' - H''$ ) вдоль профиля стены. Если максимальное отклонение  $h_m$  по всему профилю незначительно, крыша считается прямой. Если оно значительно, в этой точке – вершина треугольной крыши высотой  $h_m$ , а наклону соответствует средний наклон линий регрессии в обе стороны от этой точки (оставшаяся часть профиля считается прямой). Профили накладываются на соответствующие стороны границы крыши, продолжают до противоположных сторон и пересекаются друг с другом.

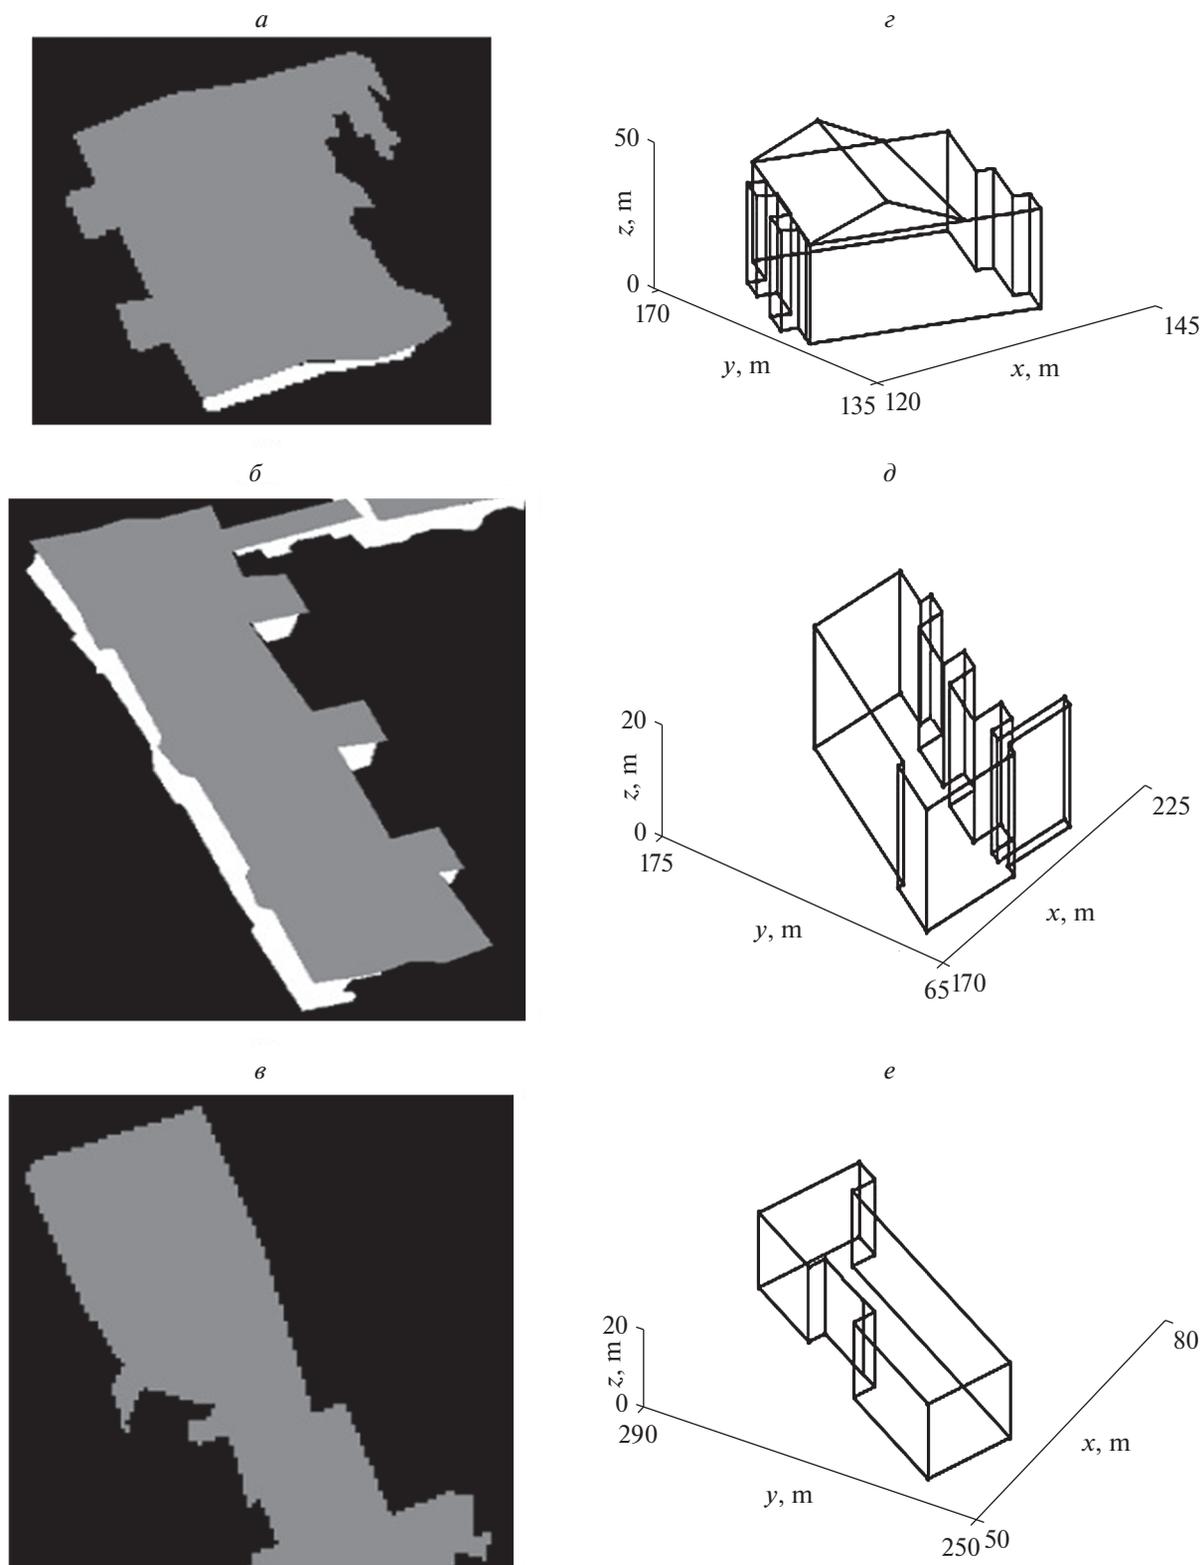


Рис. 9. Примеры восстановленных по растрам (*a*, *б*, *в*) 3D-моделей объектов  $\xi_1$  (*z*),  $\xi_2$  (*д*),  $\xi_3$  (*е*).

6. Трехмерная модель объекта складывается из контуров крыши объекта, крыш его пристроек и надстроек (замкнутые линии  $G$ ), а также ортогональных отрезков высот  $H$  и превышений  $H'$  и  $H''$  (при наличии стен). Объект масштабируется на  $m$  по осям абсцисс и ординат и на  $m_3$  по оси аппликат. Географические координаты объекта берутся как координаты геометрического центра объекта на снимке.

На рис. 9 приведены примеры трехмерных моделей объектов, построенных по предложенной методике. Объект  $\xi_1$  обособлен от других объектов, а  $\xi_2$  “слипается” с другим объектом, относительно которого он является пристройкой.  $\xi_3$  находится на границе изображения и частично скрыт, для него отсутствует растр стен, поэтому строится только 2D-модель (для таких объектов принимается средняя высота 3-этажного здания  $H = 3H_0$ ,  $H_0 \sim 3.2$  м – высота одного этажа). Масштабирующие коэффициенты, полученные для данного изображения:  $m_1 = m_2 \sim 0.21$ ,  $m_3 \sim 1.09$ .

По результатам проведенной обработки получены оценки площади зданий в основании, которые составили соответственно 320, 1400, 210 м<sup>2</sup>. Получены также соответствующие оценки объемов зданий: 1250, 29 000, 1900 м<sup>3</sup>.

## ЗАКЛЮЧЕНИЕ

В работе предложен многомасштабный метод построения трехмерных моделей объектов земной поверхности по отдельному ортотрансформированному спутниковому изображению, состоящий из этапов интегрального и локального анализа спутниковых изображений, причем каждый из этапов включает в себя композицию традиционных и нейросетевых методов.

Используемые нейросети построены на базе полносверточной топологии U-Net, расширенной и дополненной авторами для задач интерпретации аэрокосмических изображений.

Целью интегрального анализа является локализация интересующих объектов при сегментации изображений и извлечение релевантной этим объектам информации: тематических и пространственных классов отдельных пикселей, теней и т.д.

Локальный анализ направлен на извлечение данных, необходимых для определения трехмерных геометрических характеристик объекта, и их интерпретацию. Локальный анализ поддерживает построение моделей как типовых объектов, обладающих низкой вариативностью по заранее известным признакам, так и зданий или сооружений пря-

моугольной (обобщаемой до произвольной) пространственной конфигурации.

В работе описан подход к восстановлению трехмерной модели ригидных объектов по одному изображению без использования метаданных на базе четырех информативных классов, выявляемых по результатам машинного обучения: рельс и опорных железнодорожных столбов для оценки масштабирующих коэффициентов, крыш и стен для оценки формы основания и высоты строений. Приведены примеры трехмерных моделей трех зданий, восстановленных по растрам областей классов стен и крыш.

Получаемые с помощью предложенного метода трехмерные модели можно использовать в качестве данных для ГИС и систем поддержки принятия решений на их основе. Такие данные применимы для мониторинга протяженных инфраструктурных объектов и их периферии как основы для художественной или научной визуализации.

Перспективными направлениями развития метода является его интеграция с методами интерактивного обучения; расширение тематического охвата моделируемых объектов, развитие методов разрешения ситуаций неопределенности.

## ИСТОЧНИК ФИНАНСИРОВАНИЯ

Исследования выполнены при поддержке Минобрнауки России (уникальный идентификатор проекта RFMEFI60719X0312).

## СПИСОК ЛИТЕРАТУРЫ

- Бондур В.Г.* Аэрокосмические методы и технологии мониторинга нефтегазовых территорий и объектов нефтегазового комплекса // Исслед. Земли из космоса. 2010. № 6. С. 3–17.
- Бондур В.Г.* Космический мониторинг эмиссий малых газовых компонент и аэрозолей при природных пожарах в России // Исслед. Земли из космоса. 2015. № 6. С. 21–35.  
<https://doi.org/10.7868/S0205961415060032>
- Бондур В.Г.* Методы моделирования полей излучения на входе аэрокосмических систем дистанционного зондирования // Исслед. Земли из космоса. 2000а. № 5. С. 16–27.
- Бондур В.Г.* Моделирование двумерных случайных полей яркости на входе аэрокосмической аппаратуры методом фазового спектра // Исслед. Земли из космоса. 2000б. № 5. С. 28–44.
- Бондур В.Г.* Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исслед. Земли из космоса. 2014. № 1. С. 4–16.  
<https://doi.org/10.7868/S0205961414010035>

- Бондур В.Г., Аржененко Н.И., Линник В.Н., Титова И.Л.* Моделирование многоспектральных аэрокосмических изображений динамических полей яркости // Исслед. Земли из космоса. 2003. № 2. С. 3–17.
- Бондур В.Г., Воробьев В.Е.* Космический мониторинг импактных районов Арктики // Исслед. Земли из космоса. 2015. № 4. С. 4–24.  
<https://doi.org/10.7868/S0205961415040028>
- Бондур В.Г., Воробьев В.Е., Гребенюк Ю.В., Сабинин К.Д., Серебряный А.Н.* Исследования полей течений и загрязнений прибрежных вод на Геленджикском шельфе Черного моря с использованием космических данных // Исслед. Земли из космоса. 2012. № 4. С. 3–11.
- Бондур В.Г., Воробьев В.Е., Лукин А.А.* Космический мониторинг состояния северных территорий, нарушенных нефтедобычей // Исслед. Земли из космоса. 2016. № 6. С. 35–44.  
<https://doi.org/10.7868/S0205961416060014>
- Бондур В.Г., Гордо К.А., Кладов В.Л.* Пространственно-временные распределения площадей природных пожаров и эмиссий углеродсодержащих газов и аэрозолей на территории северной Евразии по данным космического мониторинга // Исслед. Земли из космоса. 2016. № 6. С. 3–20.  
<https://doi.org/10.7868/S0205961416060105>
- Бондур В.Г., Зубков Е.В.* Выделение мелкомасштабных неоднородностей оптических характеристик верхнего слоя океана по многозональным спутниковым изображениям высокого разрешения. Часть 1. Эффекты сброса дренажных каналов в прибрежные акватории // Исслед. Земли из космоса. 2005. № 4. С. 54–61.
- Бондур В.Г., Савин А.И.* Концепция создания систем мониторинга окружающей среды в экологических и природно-ресурсных целях // Исслед. Земли из космоса. 1992. № 6. С. 70–78.
- Бондур В.Г., Савин А.И.* Принципы моделирования полей сигналов на входе аппаратуры ДЗ аэрокосмических систем мониторинга окружающей среды // Исслед. Земли из космоса. 1995. № 4. С. 24–33.
- Бондур В.Г., Килер Р.Н., Старченков С.А., Рыбакова Н.И.* Мониторинг загрязнений прибрежных акваторий с использованием многоспектральных спутниковых изображений высокого пространственного разрешения // Исслед. Земли из космоса. 2006. № 6. С. 42–49.
- Бондур В.Г., Старченков С.А.* Методы и программы обработки и классификации аэрокосмических изображений // Изв. ВУЗов. Геодезия и аэрофотосъемка. 2001. № 3. С. 118–143.
- Бондур В.Г., Чимитдоржиев Т.Н.* Анализ текстуры радиолокационных изображений растительности // Изв. ВУЗов. Геодезия и аэрофотосъемка. 2008а. № 5. С. 9–14.
- Бондур В.Г., Чимитдоржиев Т.Н.* Дистанционное зондирование растительности оптико-микроволновыми методами // Изв. ВУЗов. Геодезия и аэрофотосъемка. 2008б. № 6. С. 64–73.
- Казарян М.Л., Рихтер А.А., Шахраманьян М.А.* Метод автоматизации оценки индексов подстилающей поверхности и их изменения во времени по космическим изображениям и его применение при оценке состояния окружающей среды в окрестности полигонов твердых бытовых отходов // Фундаментальные исследования. 2016. № 8. С. 52–58.
- Казарян М.Л., Рихтер, А.А., Шахраманьян М.А.* Методика автоматического детектирования компонент объектов захоронения отходов по космическим изображениям // Изв. Томского политехнического университета, Инжиниринг георесурсов. 2017. Т. 328. № 3. С. 46–53.
- Казарян М.Л., Рихтер А.А., Шахраманьян М.А., Недков Р.* Космический мониторинг объектов захоронения твердых бытовых отходов и промышленных отходов: теоретико-методические и социально-экономические аспекты: [монография] // Научно-издательский центр ИНФРА-М, 2018.
- Казарян М.Л., Рихтер А.А., Шахраманьян М.А., Недков Р.* Мониторинг и прогнозирование социально-экономического развития регионов на основе анализа космических снимков : [монография] // Научно-издательский центр ИНФРА-М, 2018.
- Казарян М.Л., Шахраманьян М.А., Мурынин А.Б., Рихтер А.А.* Построение 3D-моделей ригидных объектов по одному изображению методом пространственных сеток // Информация и космос. 2018. № 4. С. 90–102.
- Кудряшов А.П., Соловьев И.В.* Реконструкция текстурированной модели городского пространства по топографическому плану и фотоснимкам // Программные продукты и системы / Software & Systems, 2019. Т. 3. № 32.  
<https://doi.org/10.15827/0236-235X.127.496-503>
- Мурынин А.Б., Матвеев И.А.* Принципы построения системы стереоскопического зрения для управления движением робота // Известия РАН. Теория и системы управления. 2003. № 3. С. 184–192.
- Мурынин А.Б., Рихтер А.А.* Особенности применения методов и алгоритмов реконструкции трехмерной формы ригидных объектов по данным панорамной съемки // Машинное обучение и анализ данных, 2018. Т. 4. № 4. С. 235–247.  
<https://doi.org/10.21469/22233792.4.4.02>
- Мурынин А.Б., Рихтер А.А., Шахраманьян М.А.* Выбор информативных признаков для выделения областей размещения отходов по космическим изображениям высокого пространственного разрешения // Исслед. Земли из космоса. 2019. № 2. С. 29–44.
- Рихтер А.А., Шахраманьян М.А. Казарян М.Л., Мурынин А.Б.* Разработка метода оценки степени деградации почвы на основе данных долгосрочных наблюдений // Фундаментальные исследования. 2015. № 2(14). С. 3095–3099.
- Рихтер А.А., Шахраманьян М.А.* Информационные и учебно-методические основы 3D-моделирования (теория и практика): Учебно-методическое пособие. М.: НИЦ ИНФРА-М, 2018. 239 с.
- Савин А.И., Бондур В.Г.* Научные основы создания и диверсификации глобальных аэрокосмических систем // Оптика атмосферы и океана. 2000. Т. 13. № 1. С. 46–62.
- Соколова Н.О.* Распознавание контуров зданий на спутниковых изображениях высокого пространственного разрешения // Вестник ХНТУ. 2015. № 3(54). С. 610–614.

- Тужилкин А.Ю.* Распознавание и реконструкция 3D-объектов по спутниковым изображениям на основе сравнения спектров графов // *Фундаментальные исследования*, Россия, 2015. № 2. С. 3727–3732.
- Шахраманьян М.А., Казарян М.Л., Рихтер А.А.* Построение 3D-моделей ригидных объектов по косвенным изображениям методом координатных сеток // *Информация и космос*. 2018. № 3(8). С. 104–110.
- Шахраманьян М.А., Рихтер А.А., Мурынин А.Б., Казарян М.Л.* Методика построения 3D-модели объектов правильной формы по одному изображению и ее применение в задаче космического мониторинга объектов захоронения отходов // *Информация и космос*. 2018. № 2 (8). С. 76–81.
- Alobeid A., Jacobsen K., Heipke C.* Comparison of Matching Algorithms for DSM Generation in Urban Areas from Ikonos Imagery // *J. Photogrammetric Engineering & Remote Sensing*. 2010. V. 76. P. 1041–1050.
- Abdunaser E. Abduelmula.* High Resolution Satellite Image Analysis and Rapid 3D Model Extraction for Urban Change Detection // *Faculty of Science University of Port*. June 2015. 213 p. URL: <https://core.ac.uk/download/pdf/143400957.pdf>.
- Amaia Salvador, M'riam Bellver, V'ictor Campos, Manel Baradad, Ferran Marques, Jordi Torres, Xavier Giro-i-Nieto.* Recurrent Neural Networks for Semantic Instance Segmentation, 2019 // URL: <https://arxiv.org/pdf/1712.00617.pdf>.
- Amirkolaee H.A., Arefi H.* Height estimation from single aerial images using a deep convolutional encoder-decoder network // *ISPRS J. Photogramm. Remote Sens.* 2019. V. 149. P. 50–66.
- Arsalan Mousavian, Dragomir Anguelov, John Flynn.* 3D-Bounding Box Estimation Using Deep Learning and Geometry, 2015 // URL: <https://arxiv.org/pdf/1612.00496.pdf>.
- Bert De Brabandere, Davy Neven, Luc Van Gool.* Semantic Instance Segmentation with a Discriminative Loss Function, 2017 // URL: <https://arxiv.org/pdf/1708.02551.pdf>.
- Bittner K., D'Angelo P., Körner M., Reinartz P.* DSM-to-LoD2: Spaceborne Stereo Digital Surface Model Refinement // *Remote Sensing*, 2018, V. 10. P. 1926.
- Bondur V.* Complex Satellite Monitoring of Coastal Water Areas // *31st International Symposium on Remote Sensing of Environment*. ISRSE, 2005, 7 p.
- Bondur V.G.* Satellite monitoring and mathematical modelling of deep runoff turbulent jets in coastal water areas // in book *Waste Water—Evaluation and Management*, ISBN 978-953-307-233-3, InTech, Croatia. 2011. P. 155–180. <http://www.intechopen.com/articles/show/title/satellite-monitoring-and-mathematical-modelling-of-deep-runoff-turbulent-jets-in-coastal-water-areas>.
- Fatemeh Alidoost, Hossein Arefi.* A CNN Based Approach for Automatic Building Detection and Recognition of Roof Types Using a Single Aerial Image // *PFG*, Germany. 2018. V. 86. P. 235–248.
- Fatemeh Alidoost, Hossein Arefi, Federico Tombari.* 2D Image-To-3D Model: Knowledge-Based 3D Building Reconstruction (3DBR) Using Single Aerial Images and Convolutional Neural Networks (CNNs) // *Remote Sens*, USA, 2019. V. 11. 2219. 25 p. <https://doi.org/10.3390/rs11192219>
- Fua P.* A parallel stereo algorithm that produces dense depth maps and preserves image features // *Int. J. machine Vision and Applications*, 1991.
- Ghamisi P., Yokoya N.* IMG2DSM: Height Simulation from Single Imagery Using Conditional Generative Adversarial Net. // *IEEE Geosci. Remote Sens. Lett.* 2018. V. 5. P. 794–798.
- Hirschmüller H.* Stereo Processing by Semi-global Matching and Mutual Information // *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, V. 30. № 2. P. 328–341.
- Hamzah R.A., Ibrahim H.* Literature Survey on Stereo Vision Disparity Map Algorithms // *Journal of Sensors*. Volume 2016, Article ID 8742920, 23 p. <https://doi.org/10.1155/2016/8742920>
- Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi.* You Only Look Once: Unified, Real-Time Object Detection, 2016 // URL: <https://arxiv.org/pdf/1506.02640.pdf>.
- Kaiming He, Georgia Gkioxari, Piotr Dollár, Ross Girshick.* Mask R-CNN, 2018 // URL: <https://arxiv.org/pdf/1703.06870.pdf>.
- Kaiser P., Wegner J.D., Aurélien L., Jaggi M., Hofmann T., Schindler K.* Learning Aerial Image Segmentation from Online Maps // *IEEE Trans. Geosci. Remote Sens.* 2017. V. 55. P. 6054–6068.
- Kazaryan M.L., Schahramanian M.A., Richter A.A.* Space Monitoring of the Earth on the Presence of Solid Domestic Wastes Using a Discrete Orthogonal Transforms // *Serbian journal of electrical engineering*. 2017. V. 14. № 3. P. 343–364.
- Konstantin Sofiiuk, Olga Barinova, Anton Konushin.* AdaptIS: Adaptive Instance Selection Network, 2019 // URL: <https://arxiv.org/pdf/1909.07829.pdf>.
- Min Bai Raquel Urtasun.* Deep Watershed Transform for Instance Segmentation, 2017 // URL: <https://arxiv.org/pdf/1611.08303.pdf>.
- Mou L., Member S., Zhu X.X., Member S.* IM2HEIGHT: Height Estimation from Single Monocular Imagery via Fully Residual Convolutional-Deconvolutional Network, 2018. <https://arxiv.org/pdf/1802.10249.pdf>.
- Olaf Ronneberger, Philipp Fischer, Thomas Brox.* U-Net: Convolutional Networks for Biomedical Image Segmentation, 2015 // URL: <https://arxiv.org/pdf/1505.04597.pdf>.
- Persello C., Stein A.* Deep Fully Convolutional Networks for the Detection of Informal Settlements in VHR // *Images. IEEE Geosci. Remote Sens. Lett.* 2017, V. 14. P. 2325–2329.
- Richter A.A., Kazaryan M.L., Shakhramanyan M.A., Voronin V.V.* Pattern recognition algorithm using descriptors combined radio and visible spectra // *Proc. SPIE Vol. 10221, Mobile Multimedia/Image Processing, Security, and Applications 1022107*. 2017. <https://doi.org/10.1117/12.2262875>
- Richter A.A.* Some Aspects of Visual Detection of Dumps // Open access peer-reviewed chapter in book “Lean Manufacturing”, Submitted: September 5th 2018 Reviewed: September 28th 2018 Published: June 28th 2019. <https://doi.org/10.5772/intechopen.81726>

URL: <https://www.intechopen.com/online-first/some-aspects-of-visual-detection-of-dumps>.

*Shakhramanyan M.A., Kazaryan M.L., Richter A.A.* Space Monitoring of Anthropogenic Impacts on Soils and the Water Environment Associated with Solid Domestic Waste: Scientific and Educational Aspects (Space Environmental Watch) // *Ecological Engineering and Environment Protection*. 2017. № 10. P. 5–12. URL: <http://ecoleng.org/archive/eContents10.2017.html>.

*Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun.* Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, 2016 // URL: <https://arxiv.org/pdf/1506.01497.pdf>.

*Sherrie Wang, William Chen, Sang Michael Xie, George Azhari, David B. Lobell.* Weakly Supervised Deep Learning for Segmentation of Remote Sensing Imagery // *Remote Sens. USA*, 2020, 12, 207. 25 p. <https://doi.org/10.3390/rs12020207>

*Tsung-Yi Lin, Priya Goyal, Ross Girshick, Kaiming He, Piotr Dollár.* Focal Loss for Dense Object Detection, 2018 // URL: <https://arxiv.org/pdf/1708.02002.pdf>.

*Umüt Gunes Sefercik, Serkan Karakis, Caglar Bayik, Mehmet Alkan, Naci Yastikli.* Contribution of Normalized DSM to Automatic Building Extraction from HR Mono Optical Satellite Imagery // *European J. Remote Sensing, Turkey*, 2014, V. 47. P. 575–591. <https://doi.org/10.5721/EuJRS20144732>

*Wen Q., Jiang K., Wang W., Liu Q., Guo Q., Li L., Wang P.* Automatic building extraction from google earth images under complex backgrounds based on deep instance segmentation network. // *Sensors*. 2019. V. 19. P. 333.

*Sun X., Li Q., Yang B.* Compositional Structure Recognition of 3D Building Models Through Volumetric Analysis // *IEEE Access*, 2018. V. 6. P. 33953–33968.

*Yaning Yi, Zhijie Zhang, Wanchang Zhang, Chuanrong Zhang, Weidong Li, Tian Zhao.* Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network // *Remote Sens. USA*. 2019. V. 11. P. 1774. 19 p. <https://doi.org/10.3390/rs11151774>

## Construction of Three-Dimensional Models of Rigid Objects from Satellite Images of High Spatial Resolution Using Convolutional Neural Networks

O. G. Gvozdev<sup>1,3</sup>, V. A. Kozub<sup>1</sup>, N. V. Kosheleva<sup>1</sup>, A. B. Murynin<sup>1,2</sup>, and A. A. Richter<sup>1</sup>

<sup>1</sup>*AEROCOSMOS Research Institute for Aerospace Monitoring, Moscow, Russia*

<sup>2</sup>*Federal Research Center “Computer Science and Control” of the Russian Academy of Sciences, Moscow, Russia*

<sup>3</sup>*State University of Geodesy and Cartography, Moscow, Russia*

A method for constructing three-dimensional models of rigid objects from one satellite image is described, based on the use of two convolutional neural networks that sequentially process high-resolution satellite images. The first neural network performs integral image analysis for the purpose of segmentation and selection of objects of specified physical classes. The second neural network performs local image analysis and works with images segmented by the first neural network in areas in the image, presumably containing objects of specified classes. An algorithm for reconstructing a three-dimensional model of an object from raster areas of a segmented image obtained from the results of local analysis is described, based on regression analysis, an assessment of equivalent figures, as well as linearization and polarization of contours. The results of the operation of the algorithm are given on the example of railway infrastructure facilities. The results of the construction of three-dimensional models of three objects of the railway infrastructure, revealed by the results of the operation of neural networks for four informative classes of areas, such as roofs, walls, rails, support pillars, are shown. Standard dimensions such as rail gauge (1.52 m) and pole height (11.35 m) are used to estimate scaling factors to provide estimates of base dimensions and object heights. The possibility of building 3D models of objects of various areas from 210 to 4200 m<sup>2</sup> is shown.

**Keywords:** satellite imagery, 3D model, raster domain, artificial neural network, convolutional network, machine learning, infrastructure

### REFERENCES

*Abdunaser E. Abduelmula.* High Resolution Satellite Image Analysis and Rapid 3D Model Extraction for Urban Change Detection // *Faculty of Science University of Port. June* 2015. 213 p. URL: <https://core.ac.uk/download/pdf/143400957.pdf>.

*Amaia Salvador, M'iriam Bellver, Victor Campos, Manel Baradad, Ferran Marques, Jordi Torres, Xavier Giro-i-Nieto.*

Recurrent Neural Networks for Semantic Instance Segmentation, 2019 // URL: <https://arxiv.org/pdf/1712.00617.pdf>.

*Amirkolae H.A., Arefi H.* Height estimation from single aerial images using a deep convolutional encoder-decoder network // *ISPRS J. Photogramm. Remote Sens.* 2019. V. 149. P. 50–66.

*Arsalan Mousavian, Dragomir Anguelov, John Flynn.* 3D-Bounding Box Estimation Using Deep Learning and Geometry, 2015 // URL: <https://arxiv.org/pdf/1612.00496.pdf>.

- Bert De Brabandere, Davy Neven, Luc Van Gool.* Semantic Instance Segmentation with a Discriminative Loss Function, 2017 // URL: <https://arxiv.org/pdf/1708.02551.pdf>.
- Bittner K., D'Angelo P., Körner M., Reinartz P.* DSM-to-LoD2: Spaceborne Stereo Digital Surface Model Refinement // *Remote Sensing*, 2018. V. 10. P. 1926.
- Bondur V.* Complex Satellite Monitoring of Coastal Water Areas // 31st International Symposium on Remote Sensing of Environment. ISRSE, 2005. 7 p.
- Bondur V.G.* Aerospace Methods and Technologies for Monitoring Oil and Gas Areas and Facilities // *Izvestiya, Atmospheric and Oceanic Physics*. 2011. V. 47. № 9. P. 1007–1018. DOI: 10.1134/S0001433811090039
- Bondur V.G.* Satellite monitoring of trace gas and aerosol emissions during wildfires in Russia // *Izvestiya, Atmospheric and Oceanic Physics*. 2016. V. 52. № 9. P. 1078–1091. DOI: 10.1134/S0001433816090103
- Bondur V.G.* Metodi modelirovaniya polei izlutseniya na vhode aerokosmitshtskih system distanstonnogo zondirovaniya (The Methods of the Emission Model Field Which Be Formed on Enter of Airspace Remote Sensing System) // *Issledovanie Zemli iz Kosmosa*. 2000a. № 5. P. 16–27 (In Russian).
- Bondur V.G.* Phase-Spectral Method's Modeling of Two-Dimension Stochastic Brightness Field Formed at the Airspace Apparatus Entrance // *Issledovanie Zemli iz Kosmosa*. 2000b. № 5. P. 28–44 (In Russian).
- Bondur V.G.* Modern Approaches to Processing Large Hyperspectral and Multispectral Aerospace Data Flows. *Izvestiya, Atmospheric and Oceanic Physics*. 2014. V. 50. № 9. P. 840–852. DOI: 10.1134/S0001433814090060
- Bondur V.G.* Satellite monitoring and mathematical modeling of deep runoff turbulent jets in coastal water areas // in book *Waste Water – Evaluation and Management*, ISBN 978-953-307-233-3, InTech, Croatia. 2011. P. 155–180. <http://www.intechopen.com/articles/show/title/satellite-monitoring-and-mathematical-modelling-of-deep-runoff-turbulent-jets-in-coastal-water-areas>
- Bondur V.G., Arzhenenko N.I., Linnik V.N., Titova I.L.* Modelirovanie mnogospektralnykh aerokosmicheskikh izobrazheniy dinamicheskikh poley yarkosti [The Simulation of Multispectral Air-Space Images of Dynamic Brightness Fields] // *Issledovanie Zemli iz Kosmosa*, 2003. № 2. P. 3–17 (In Russian).
- Bondur V.G., Vorobyov V.E.* Satellite Monitoring of Impact Arctic Regions // *Izvestiya, Atmospheric and Oceanic Physics*. 2015. V. 51. № 9. P. 949–968. DOI: 10.1134/S0001433815090054.
- Bondur V.G., Vorobyov V.E., Grebenyuk Yu.V., Sabinin K.D., Serebryany A.N.* Study of fields of currents and pollution of the coastal waters on the Gelendzhik Shelf of the Black Sea with space data // *Izvestiya, Atmospheric and Oceanic Physics*. 2013. V. 49. № 9. P. 886–896. DOI: 10.1134/S000143381309003X
- Bondur V.G., Vorobyov V.E., Lukin A.A.* Satellite monitoring of the northern territories disturbed by oil production // *Izvestiya, Atmospheric and Oceanic Physics*. 2017. V. 53. № 9. P. 1007–1015. DOI: 10.1134/S0001433817090067
- Bondur V.G., Gordo K.A., Klodov V.L.* Spacetime distributions of wildfire areas and emissions of carbon-containing gases and aerosols in northern Eurasia according to satellite-monitoring data // *Izvestiya, Atmospheric and Oceanic Physics*, 2017. V. 53. № 9. P. 859–874. DOI: 10.1134/S0001433817090055
- Bondur V.G., Zubkov E.V.* Showing up the small-scale ocean upper layer optical inhomogeneities by the multispectral space images with the high surface resolution. Part 1. The canals and channels drainage effects at the coastal zone // *Issledovanie Zemli iz Kosmosa*. 2005. № 4. P. 54–61 (In Russian).
- Bondur V.G., Savin A.I.* Design a system to monitor the environment for purposes relating to ecology and natural-resources // *Soviet Journal of Remote Sensing*. 1993. V. 10. № 6. P. 1078–1093.
- Bondur V.G., Savin A.I.* Modelling of signals on input to remote sensing equipment of aerospace environment monitoring systems // *Earth Obs. Rem. Sens*. 1996. V. 13. P. 539–553.
- Bondur V.G., Keeler R.N., Starchenkov S.A., Rybakova N.I., Bondur V.G., Keeler R.N., Starchenkov S.A., Rybakova N.I.* Monitoring zagryazneniy pribrezhnykh akvatoriy s ispolzovaniem mnogospektralnykh sputnikovyyh izobrazheniy vysokogo prostranstvennogo razresheniya [Monitoring of the pollution of the ocean coastal water areas using space multispectral high resolution imagery] // *Issledovanie Zemli iz Kosmosa*. 2006. № 6. P. 42–49 (In Russian).
- Bondur V.G., Starchenkov S.A.* Metody i programmy obrabotki i klassifikatsii aerokosmicheskikh izobrazheniy [Methods and Programs for Aerospace Imagery Processing and Classification] // *Izvestia Vuzov. Geodesy and Aerophotography*. 2001. № 3. P. 118–143 (In Russian).
- Bondur V.G., Chimitdorzhiev T.N.* Analiz tekstury radiolokatsionnykh izobrazheniy rastitelnosti [Texture Analysis of Radar Images of Vegetation] // *Izvestiya vysshikh uchebnykh zavedenii. Geodeziya i aerofotosemka*. 2008a. № 5. P. 9–14 (In Russian).
- Bondur V.G., Chimitdorzhiev T.N.* Distantionnoe zondirovanie rastitel'nosti optiko-mikrovolnovymi metodami [Remote Sensing of Vegetation by Optical Microwave Methods] // *Izvestiya vysshikh uchebnykh zavedenii. Geodeziya i Aerofotosemka*. 2008b. № 6. P. 64–73 (In Russian).
- Fatemeh Alidoost, Hossein Arefi.* A CNN Based Approach for Automatic Building Detection and Recognition of Roof Types Using a Single Aerial Image // *PFG, Germany*, 2018, V. 86. P. 235–248.
- Fatemeh Alidoost, Hossein Arefi, Federico Tombari.* 2D Image-To-3D Model: Knowledge-Based 3D Building Reconstruction (3DBR) Using Single Aerial Images and Convolutional Neural Networks (CNNs) // *Remote Sens. USA*. 2019. V. 11. 2219. 25 p. DOI: 10.3390/rs11192219
- Fua P.* A parallel stereo algorithm that produces dense depth maps and preserves image features // *Int. J. machine Vision and Applications*, 1991.
- Ghamisi P., Yokoya N.* IMG2DSM: Height Simulation from Single Imagery Using Conditional Generative Adversarial Net. // *IEEE Geosci. Remote Sens. Lett.* 2018. V. 5. P. 794–798.

- Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi.* You Only Look Once: Unified, Real-Time Object Detection, 2016 // URL: <https://arxiv.org/pdf/1506.02640.pdf>.
- Kaiming He, Georgia Gkioxari, Piotr Dollár, Ross Girshick.* Mask R-CNN, 2018 // URL: <https://arxiv.org/pdf/1703.06870.pdf>.
- Kaiser P., Wegner J.D., Aurélien L., Jaggi M., Hofmann T., Schindler K.* Learning Aerial Image Segmentation from Online Maps // IEEE Trans. Geosci. Remote Sens. 2017. V. 55. P. 6054–6068.
- Kazaryan M.L., Schahramanian M.A., Richter A.A.* Space Monitoring of the Earth on the Presence of Solid Domestic Wastes Using a Discrete Orthogonal Transforms // Serbian journal of electrical engineering. 2017. V. 14. № 3. P. 343–364.
- Kazaryan M.L., Richter, A.A., Shakhramanyan M.A.* A method for automating the assessment of the underlying surface indices and their changes in time from space images and its application in assessing the state of the environment in the vicinity of solid waste landfills // Fundamental research. 2016. № 8. P. 52–58 (in Russian).
- Kazaryan M.L., Richter, A.A., Shakhramanyan M.A.* Methods of automatic detection of components of waste disposal facilities using space images // Bulletin of the Tomsk Polytechnic University, Engineering of georesources. 2017. V. 328. № 3. P. 46–53 (In Russian).
- Kazaryan M.L., Richter A.A., Shakhramanyan M.A., Nedkov R.* Space monitoring of solid waste and industrial waste disposal facilities: theoretical, methodological and socio-economic aspects: [monograph] // INFRA-M Scientific and Publishing Center LLC, 2018 (In Russian).
- Kazaryan M.L., Richter A.A., Shakhramanyan M.A., Nedkov R.* Monitoring and forecasting of the socio-economic development of regions based on the analysis of space images: [monograph] // INFRA-M Scientific and Publishing Center LLC, 2018 (In Russian).
- Kazaryan M.L., Shakhramanyan M.A., Murynin A.B., Richter A.A.* Construction of 3D models of rigid objects according to one image by the method of spatial grids // Information and space. 2018. № 4. P. 90–102 (In Russian).
- Konstantin Sofiiuk, Olga Barinova, Anton Konushin.* AdaptIS: Adaptive Instance Selection Network, 2019 // URL: <https://arxiv.org/pdf/1909.07829.pdf>.
- Kudryashov A.P., Soloviev I.V.* Reconstruction of the textured model of urban space according to the topographic plan and photographs // Software products and systems/Software & Systems, Russia. 2019. V. 3. № 32 (in Russian). DOI: 10.15827/0236-235X.127.496-503
- Min Bai Raquel Urtasun.* Deep Watershed Transform for Instance Segmentation, 2017 // URL: <https://arxiv.org/pdf/1611.08303.pdf>.
- Mou L., Member S., Zhu X.X., Member S.* IM2HEIGHT: Height Estimation from Single Monocular Imagery via Fully Residual Convolutional-Deconvolutional Network, 2018 // <https://arxiv.org/pdf/1802.10249.pdf>.
- Murynin A.B., Richter A.A.* Features of the application of methods and algorithms for the reconstruction of the 3D shape of rigid objects according to panoramic survey data // Machine learning and data analysis, Russia. 2018. V. 4. № 4. P. 235–247. DOI: 10.21469/22233792.4.4.02 (In Russian).
- Murynin A.B., Richter A.A., Shakhramanyan M.A.* Selection of informative features for identifying waste disposal areas from high-spatial resolution space images // Earth exploration from space. 2019. № 2. P. 29–44 (In Russian).
- Olaf Ronneberger, Philipp Fischer, Thomas Brox.* U-Net: Convolutional Networks for Biomedical Image Segmentation, 2015 // URL: <https://arxiv.org/pdf/1505.04597.pdf>.
- Persello C., Stein A.* Deep Fully Convolutional Networks for the Detection of Informal Settlements in VHR // Images. IEEE Geosci. Remote Sens. Lett. 2017. V. 14. P. 2325–2329.
- Richter A.A.* Some Aspects of Visual Detection of Dumps // Open access peer-reviewed chapter in book “Lean Manufacturing”, Submitted: September 5th 2018 Reviewed: September 28th 2018 Published: June 28th 2019. DOI: 10.5772/intechopen.81726. URL: <https://www.intechopen.com/online-first/some-aspects-of-visual-detection-of-dumps>.
- Richter A.A., Kazaryan M.L., Shakhramanyan M.A., Voronin V.V.* Pattern recognition algorithm using descriptors combined radio and visible spectra // Proc. SPIE. 2017. V. 10221, Mobile Multimedia/Image Processing, Security, and Applications 1022107. doi: 10.1117/12.2262875.
- Richter A.A., Shakhramanyan M.A., Kazaryan M.L., Murynin A.B.* Development of a method for assessing the degree of soil degradation based on long-term observation data // Basic research. 2015. № 2 (14). P. 3095–3099 (In Russian).
- Richter A.A., Shakhramanyan M.A.* Information and educational and methodological foundations of 3D modeling (theory and practice): Educational and methodological manual. M.: NIC INFRA-M, 2018. 239 p. (In Russian).
- Savin A.I., Bondur V.G.* Nauchnye osnovy sozdaniya i diversifikacii global'nyh aerokosmicheskikh sistem (Scientific fundamentals of creation and diversification of the global aerospace systems) // Atmospheric and Oceanic Optics. 2000. V. 13. № 1. P. 38–53 (In Russian).
- Sokolova N.O.* Recognition of the contours of buildings on satellite images of high spatial resolution // Bulletin of KHNTU, Russia, 2015. № 3(54). P. 610–614 (In Russian).
- Tuzhilkin A.Yu.* Recognition and reconstruction of 3D objects from satellite images based on comparison of graph spectra // Basic research, Russia. 2015. № 2. P. 3727–3732 (In Russian).
- Shakhramanyan M.A., Kazaryan M.L., Richter A.A.* Construction of 3D models of rigid objects by indirect images using the method of coordinate grids // Information and space. 2018. № 3(8). P. 104–110 (In Russian).
- Shakhramanyan M.A., Kazaryan M.L., Richter A.A.* Space Monitoring of Anthropogenic Impacts on Soils and the Water Environment Associated with Solid Domestic Waste: Scientific and Educational Aspects (Space Environmental Watch) // Ecological Engineering and Environment Protection. 2017. № 10. P. 5–12. URL: <http://ecoleng.org/archive/eContents10.2017.html>.
- Shakhramanyan M.A., Richter A.A., Murynin A.B., Kazaryan M.L.* Methodology for constructing a 3D model of objects of the correct shape according to one image and its ap-

plication in the task of space monitoring waste disposal objects // Information and space. 2018. № 2(8). P. 76–81 (In Russian).

*Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun.* Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, 2016 // URL: <https://arxiv.org/pdf/1506.01497.pdf>.

*Sherrie Wang, William Chen, Sang Michael Xie, George Azhari, David B. Lobell.* Weakly Supervised Deep Learning for Segmentation of Remote Sensing Imagery // Remote Sens. USA. 2020. V. 12. P. 207. 25 p. doi: 10.3390/rs12020207

*Tsung-Yi Lin, Priya Goyal, Ross Girshick, Kaiming He, Piotr Dollár.* Focal Loss for Dense Object Detection, 2018 // URL: <https://arxiv.org/pdf/1708.02002.pdf>.

*Umut Gunes Sefercik, Serkan Karakis, Caglar Bayik, Mehmet Alkan, Naci Yastikli.* Contribution of Normalized DSM to

Automatic Building Extraction from HR Mono Optical Satellite Imagery // European Journal of Remote Sensing. Turkey. 2014. V. 47. P. 575–591. doi: 10.5721/EuJRS20144732

*Wen Q., Jiang K., Wang W., Liu Q., Guo Q., Li L., Wang P.* Automatic building extraction from google earth images under complex backgrounds based on deep instance segmentation network // Sensors. 2019. V. 19. P. 333.

*Sun X., Li Q., Yang B.* Compositional Structure Recognition of 3D Building Models Through Volumetric Analysis // IEEE Access. 2018. V. 6. P. 33953–33968.

*Yaning Yi, Zhijie Zhang, Wanchang Zhang, Chuanrong Zhang, Weidong Li, Tian Zhao.* Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network // Remote Sens. USA. 2019. V. 11. P. 1774. 19 p. doi:10.3390/rs11151774