

Подготовка данных для автоматического распознавания открытого грунта и областей замусоривания по космическим изображениям на примере Московского региона

Гвоздев О.Г. (1,2), Рихтер А.А. (2), Мурынин А.Б. (2,4), Касинская К.А. (3,2)

(1) МИИГАиК, Москва, Российская Федерация

(2) НИИ "АЭРОКОСМОС", Москва, Российская Федерация

(3) Московский физико-технический институт (государственный университет), Москва, Российская Федерация

(4) Федеральный исследовательский центр "Информатика и управление" РАН (ФИЦ ИУ РАН), Москва, Российская Федерация

Докладчик – Рихтер Андрей Александрович


Постановка задачи

- Получение знаний о степени антропогенного загрязнения земной поверхности актуально в связи с тем, что процесс замусоривания бытовыми и промышленными отходами становится неконтролируемым.
- Области открытого грунта и открытого мусорного покрова (ОГМ) на земной поверхности существуют объективно, независимо от регистрирующей аппаратуры и обладают рядом специфических признаков, отличающих их от окружающих фонов. Области данных классов неразрывны, имеют организованную или неорганизованную формы, обусловленную, например, мусорными полигонами или стихийными свалками соответственно.
- С точки зрения дешифрирования по спутниковым изображениям, объекты размещения отходов (ОРО), с одной стороны, человеком легко различаются по визуальным признакам, но с другой — с трудом поддаются дешифрированию классическими методами цифровой обработки. Последнее обусловлено тем, что ОРО располагают сложной системой дешифровочных признаков, по которым легко обнаружить ОРО ручным, но проблематично — автоматизированным путём. В связи с этим, следует прибегнуть к интеллектуальной обработке, совмещающей черты визуальной и цифровой обработки, точнее — к машинному обучению, основанному на использовании искусственных нейронных сетей (ИНС). Однако, как показали исследования, здесь также возникают сложности, связанные с построением обучающей и валидационной выборки, которые полностью определяют качество ИНС при её дальнейшем тестировании и функционировании.
- Основная задача проводимого исследования состоит в разработке методов выделения этих признаков на изображениях достаточно высокого качества для дальнейшей разработки методов и алгоритмов автоматизированного и автоматического выделения ОРО на спутниковых изображениях.

Постановка задачи



Открытый мусорный покров (ОМ), Калужская область, Боровский район, садовые участки Курьяново [фотографии, весна, 2019]




Открытый грунт (ОГ), поселение Щербинка, Обводная дорога, НАО г. Москва [фрагмент космического снимка, GeoEye, лето, 2014]

Постановка задачи

Пример верификации открытого замусоривания (свалка *u* в окрестности мусорного полигона Торбеево):

- а) фотосъёмка территории [июль 2017 г.]
- б) фотография свалки [июнь 2017 г.]
- в) спутниковый снимок (картографические данные Google, аккаунт Serge sp)


Окрестность дер. Торбеево, Люберецкий район, Московский регион






Область открытого грунта (2)

(1)

(а)



(б)



Пример космической (1) и панорамной (2) съёмки открытого грунта (ипподромное поле *v*) в Яндекс- [2018 г.] (а) и Google- [2019 г.] (б) картах

Трудности при сегментации открытого грунта и мусорного покрова

- Разнообразие геометрических форм и текстур, зернистость текстуры, наличие оттенков, не характерных для иных антропогенных или природных объектов. Наличие основной организованной области ОГМ и небольших областей ОГМ, случайно распределённых в её окрестности, особенно для мусорных полигонов;
- Разнообразие форм и отсутствие чёткого контура границы объекта, смешение участков с грунтовыми насыпями и дорожками, наличие объектов фона (например, бункеровозы, скреперы, компакторы, контейнеры и др.) внутри области открытого грунта и мусорного покрова (ОГМ), случайные вкрапления частиц областей в фон. В связи с этим замедляется процесс подготовки размеченных данных для обучающей выборки. В связи с трудностями выделения контура границы ОГМ при недостаточно хорошем совпадении разметки и реальных границ ОГМ точность работы искусственной нейронной сети (ИНС), например, по метрикам IoU или pixel accuracy, может быть оценена некорректно;
- Встречаемость спорных (трудноинтерпретируемых) объектов, которые могут принадлежать к любому классу из некоторого множества с близкими вероятностями. Наличие родственных классов, близких по дешифровочным признакам: для открытого грунта – грунтовые дороги, асфальтированные площадки, состриженная или редкая растительность и др.; для открытого замусоривания – кладбища самолётов, людей, насыпи грунта, склады, автостоянки и др.;
- В открытом доступе практически нет датасетов с размеченными ОГМ, например, выделение областей мусорных полигонов Московского региона в географических форматах. В связи с этим требуются затраты дополнительных ресурсов времени и памяти на разработку обучающей выборки, размер которой должен быть достаточно большой.

Основные трудности при сегментации на примере мусорного полигона



1. Линейные (мусорные дороги и др.) объекты фона на свалке
2. Нечёткость области свалки на внутренних и внешних границах (с кавальерами, дорогами и т.д.)
3. Площадные (мусорная техника и др.) объекты фона на области свалки
4. Части области свалки на фоне (свалки рассредоточенной формы)

Полигон твёрдых коммунальных отходов (ТКО) Воловичи, Коломенский район, Московский регион

Примеры изображений спорных областей


Спорные с открытым мусорным покровом



Разрушенное здание



Деревья



Строительные материалы



Строящиеся объекты




Скрытые (затенённые) участки



Склад

Спорные с открытым грунтом



Земляное полотно




Скопления грунта, строительные материалы



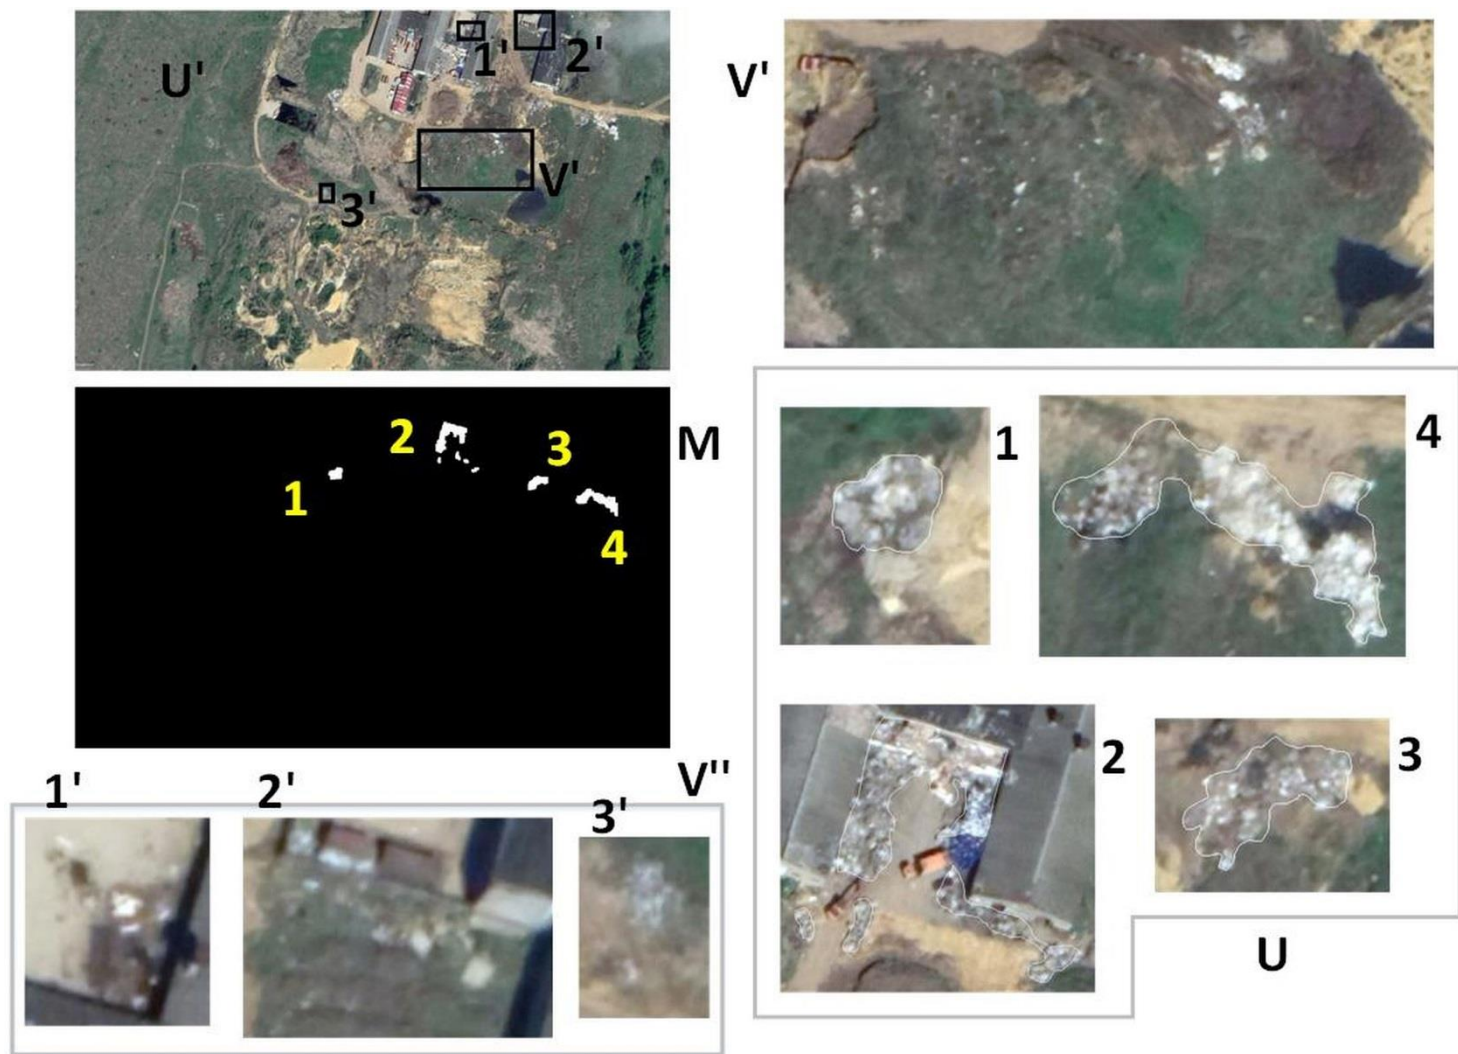
Дорожное полотно

Бетонное, асфальтированное покрытие



Редкая растительность

Формирование обучающей и тестовой выборок (на примере областей открытого мусорного покрова)



$n \sim 100$ - число снимков и соответствующих масок

$m \sim 5$ - среднее число непрерывных областей ОМ

$q \sim 100$ - число аугментированных изображений в окрестности каждой области ОМ

$N = mnq \sim 50000$ - размер обучающей выборки

U — разметка

U' — фон

$V = V' + V''$ — вычитаемая область (вводится ввиду сложности в разметке и неопределённости идентификации объектов)

1–4 — размеченные области ОМ

1'–3' — примеры вычитаемых областей

M — маска, отделяющая размеченные объекты от фона и вырезанных участков


Построение обучающей выборки на примере изображения (Михайловская Слобода, Раменский район, Московский регион)

Фрактальные свойства областей открытого мусорного покрова


Для расчёта фрактальной размерности изображение разделяется на элементы покрытия (квадраты) размером r и строится зависимость заполнения элементов покрытия от размера r . Фрактальная размерность фрагмента полутонового изображения f может быть рассчитана как коэффициент наклона линии регрессии для функции $v(u)$

$$u = \ln \frac{1}{r}, \quad v = \ln N \quad N = \sum_{k=1}^l (b_k - a_k)$$


a_k и b_k – минимальное и максимальное значение яркости, в k -м квадрате (элементе покрытия) входного изображения, l – число элементов покрытия изображения.



Пример зависимости $v(u)$ и её линии регрессии $v'(u)$ в точке ОМ







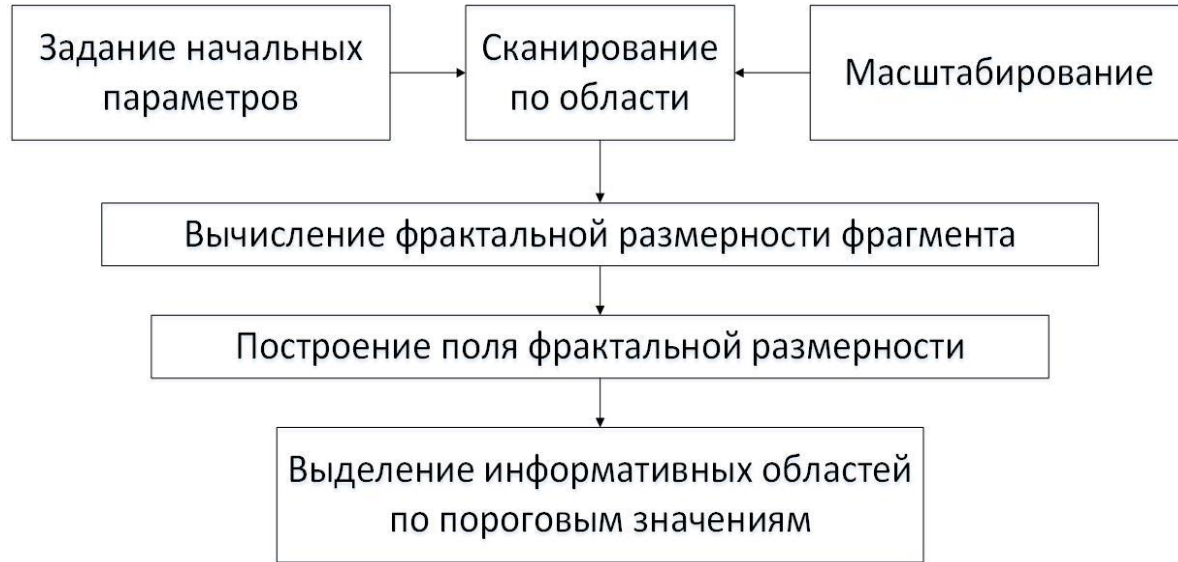
Участки замусоривания разной цветности, но близкие по фрактальной размерности




Пример участка замусоривания, сохраняющего фрактальную размерность при повороте и масштабировании

Рекультивируемый полигон ТКО Кучино, Балашихинский район, Московский регион

Детектирование открытого мусорного покрова классическими методами (фрактальный анализ)

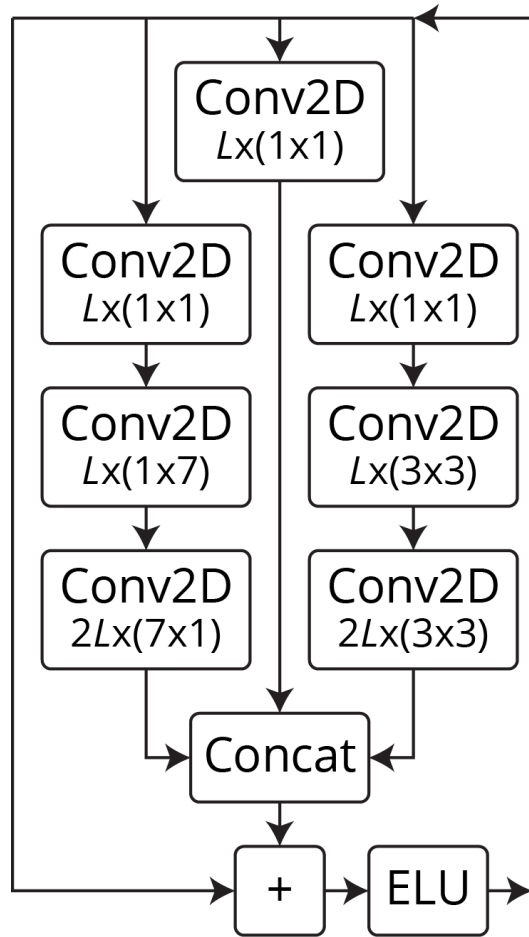


Расчёт изменения фрактальной размерности: а) входное изображение; б) поле фрактальной размерности по формуле (4); в) изображение лесного массива; г) изображение мусорного покрова; д) зависимости фрактальной размерности для лесного (f_1 , для изображения (в)) и мусорного (f_2 , для изображения (г)) покровов от порога яркости q

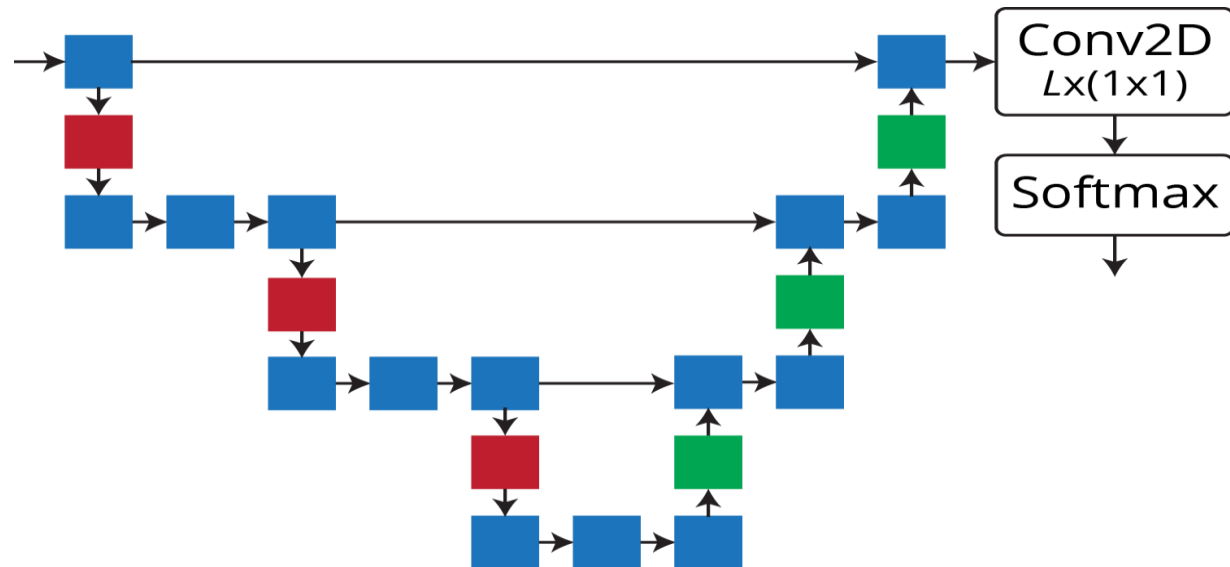


Рекультивируемый полигон ТКО Кучино, Балашихинский район, Московский регион

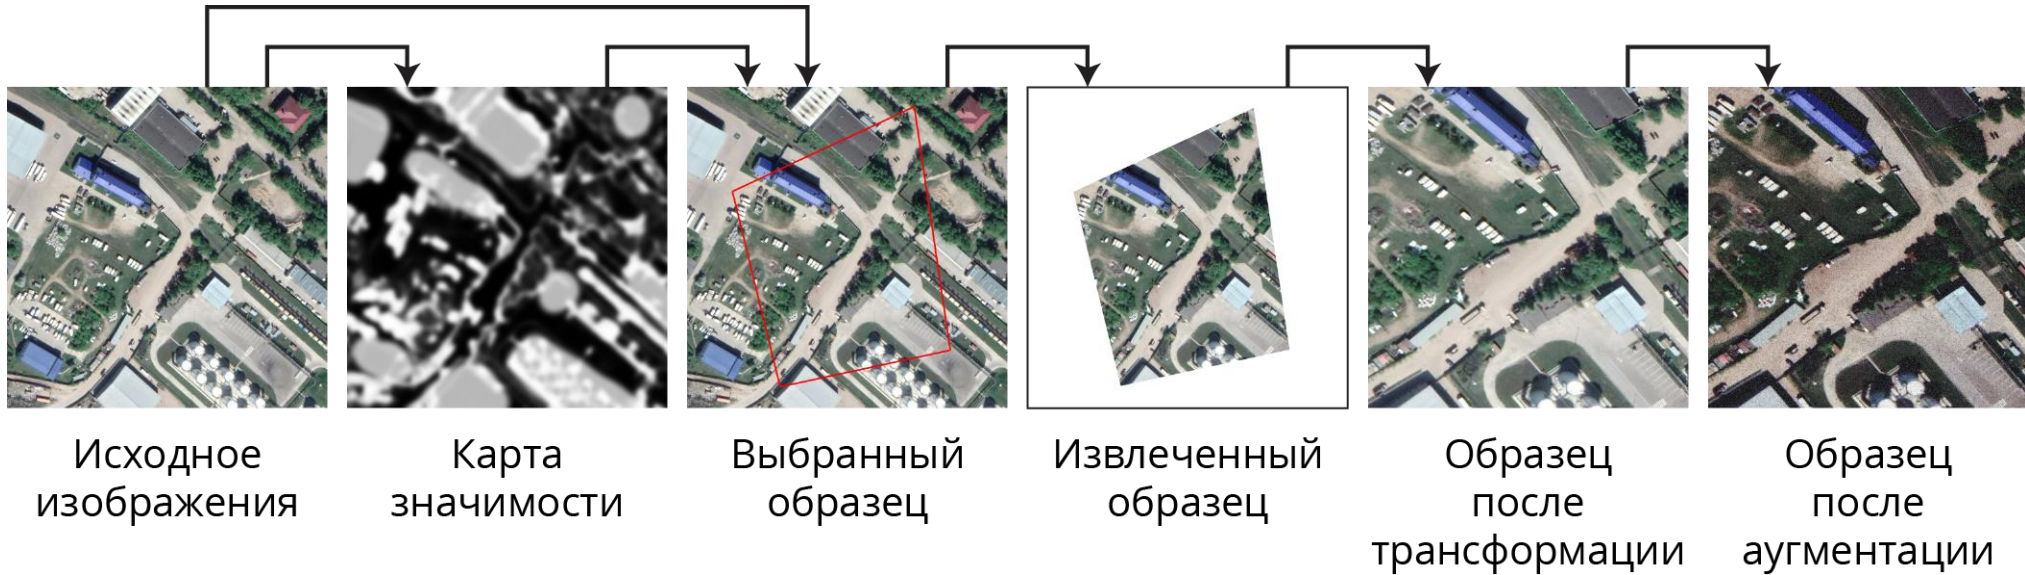
Искусственная нейронная сеть



- Частный случай **семантической сегментации**
- Базовая топология – **U-Net**
- Базовый блок – на основе **Inception-ResNet**
- Активационная функция – **ELU**
- **Squeeze-and-Excitation** для учета глобальных особенностей снимка




Подготовка данных для обучения



- **Карта значимости** – функция веса класса, локальной энтропии изображения и дополнительных пометок эксперта
- Случайная генерация множества **образцов** – полигонов на снимке
- **Оптимизационная задача** – поиск подмножества образцов, оптимальным образом покрывающих снимок пропорционально **карте значимости**
- Извлечение и аугментация каждого образца по-отдельности

Результаты обучения



Детектирование открытого мусорного покрова на участках (1–4) мусорного полигона Торбеево:
а) входные изображения; б) эталонные разметки;
в) детектирование классическими методами (на базе оценки фрактальной размерности); г) детектирование с применением ИНС

Результаты бинарной классификации для классического метода (фрактальный анализ) и с использованием ИНС

Параметр	Классический метод, ~%	Применение ИНС, %
TP (True Positive)	60	80.4
TN (True Negative)	90	87.9
FP (False Positive)	20	12.1
FN (False Negative)	10	19.5

1	0.4084 – 2.0486
2	1.9242 – 2.1091
3	1.6479 – 2.0122
4	0.6449 – 1.2783

Значения фрактальной размерности f
13

Пример сегментации на тестовой выборке



Исходное
изображение

Маска,
полученная
экспертно



Работа
нейронной сети

Значения метрик качества, выбранных для предложенного метода (вероятностный метод)

Название	Значение
Качество алгоритма (Accuracy)	0.92
Точность (Precision)	0.66
Сходство (Jaccard)	0.38

Примеры хорошей и ошибочной сегментации на тестовой выборке



Сегментация областей открытого мусорного покрова с посторонними объектами (участок мусорного полигона)



Ошибочная сегментация (антропогенный участок другого типа)

Обсуждение результатов

- Сопоставление изображений фрактальных полей, полученных по полноцветным изображениям, с соответствующей эталонной разметкой и входными изображениями диагностирует определённую корреляцию. Области, полученные при фрактальной обработке, близки с соответствующими эталонными областями. Разница между ними обусловлена: “размыванием” с перерытым грунтом и насыпями, а также нагромождениями машин и строениями; крупные свалки выявляются, а мелкие — нет; чем ниже высота съёмки, тем хуже выделяется свалка.
- Изображение мусорного покрова представляет собой структуру, состоящую из фрагментов, визуально различимые структурные свойства которых повторяются при изменении масштаба, то есть обладает свойством самоподобия, поэтому для его детектирования можно использовать фрактальные характеристики (плотность самоподобия, фрактальная размерность и её поле, точность определения и построения и др.).
- При распознавании свалок с применением ИНС описанной архитектуры отклонения от эталонной разметки объясняются, очевидно, качеством обучающей выборки (наличие “грязного” мусорного покрова). Не смотря на то что показатели ИНС существенно превосходят показатели классических методов, проведённые эксперименты обнаружили ряд проблем, определивших направления для дальнейших исследований.

Обсуждение результатов

- Свалки не склонны иметь регулярные внутренние структуры, которые хорошо распознаются ИНС, в то же время, их цвет зависит от освещения снимка в целом. С одной стороны, организованным свалкам свойственно иметь в своём составе объекты, в равной степени свойственные фону: сухой грунт (грунтовые дороги), бетонные покрытия, технику, ограждения и строения. Свалки имеют существенный разброс по размерам и могут занимать область от нескольких десятков пикселей до 80% ширины снимка. С другой стороны, используемые процедуры обучения ИНС и оценки точности её работы опираются на распознавание отдельных пикселей изображения, а не площадных объектов, которыми являются свалки.
- Обозначенные проблемы, в совокупности, приводят к невозможности в полной мере раскрыть и количественно оценить возможности ИНС для данной задачи. Их решение, по мнению авторов, требует значительно большего количества обучающих образцов, а также большей детализации классов объектов в них. В частности, предлагается выделить:
 - Фон;
 - Стихийные (не организованные) свалки;
 - Открытый мусор на организованных свалках;
 - Территория организованных свалок;
 - Объекты инфраструктуры на территории организованных свалок.

Выводы

1. Полученные результаты могут служить методической основой при решении ряда практических задач:

- Обнаружение несанкционированных объектов размещения отходов на заданной области наблюдения (населённый пункт, район, окрестность крупного объекта, природоохранная зона, прибрежная, промышленная зона и т.д.);
- Автоматизированное картографирование и разработка геоинформационных баз данных санкционированных и несанкционированных объектов;
- Оценка соблюдения требований проектирования, эксплуатации и рекультивации для мусорных полигонов и др.

2. По результатам проведённых исследований ведётся дальнейшая разработка алгоритмов интеллектуального дешифрирования свалок наряду с другими объектами земной поверхности, с использованием ИНС. Для такой разработки требуется решение следующих задач: разработка методик построения обучающих выборок для обучения создаваемых алгоритмов на основе реальных данных, получаемых с космических аппаратов и с беспилотных летательных аппаратов, а также методик, обеспечивающих оптимальное обучение ИНС для решения поставленных задач; разработка методов и алгоритмов предобработки и аугментации аэрокосмических изображений, обеспечивающих выделение выбранных информативных признаков.