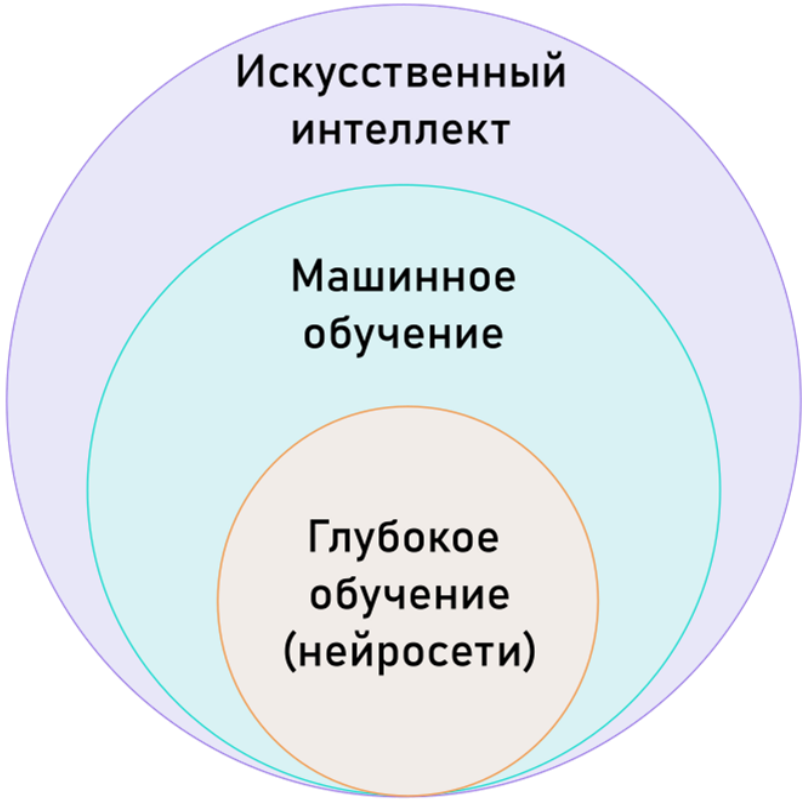
«Пространственная кросс-валидация моделей машинного обучения для классификации и сегментации растительности вулканических ландшафтов Камчатки по данным ДЗЗ»

Максимович Н. В., аспирант СПбГУ, м. н. с. лаборатории общей геоботаники БИН РАН
Научный руководитель: к. г. н. Сидорина И. Е., доцент кафедры картографии и геоинформатики СПбГУ
Научный консультант: к. б. н. Кораблёв А. П., с. н. с. лаборатории общей геоботаники БИН РАН

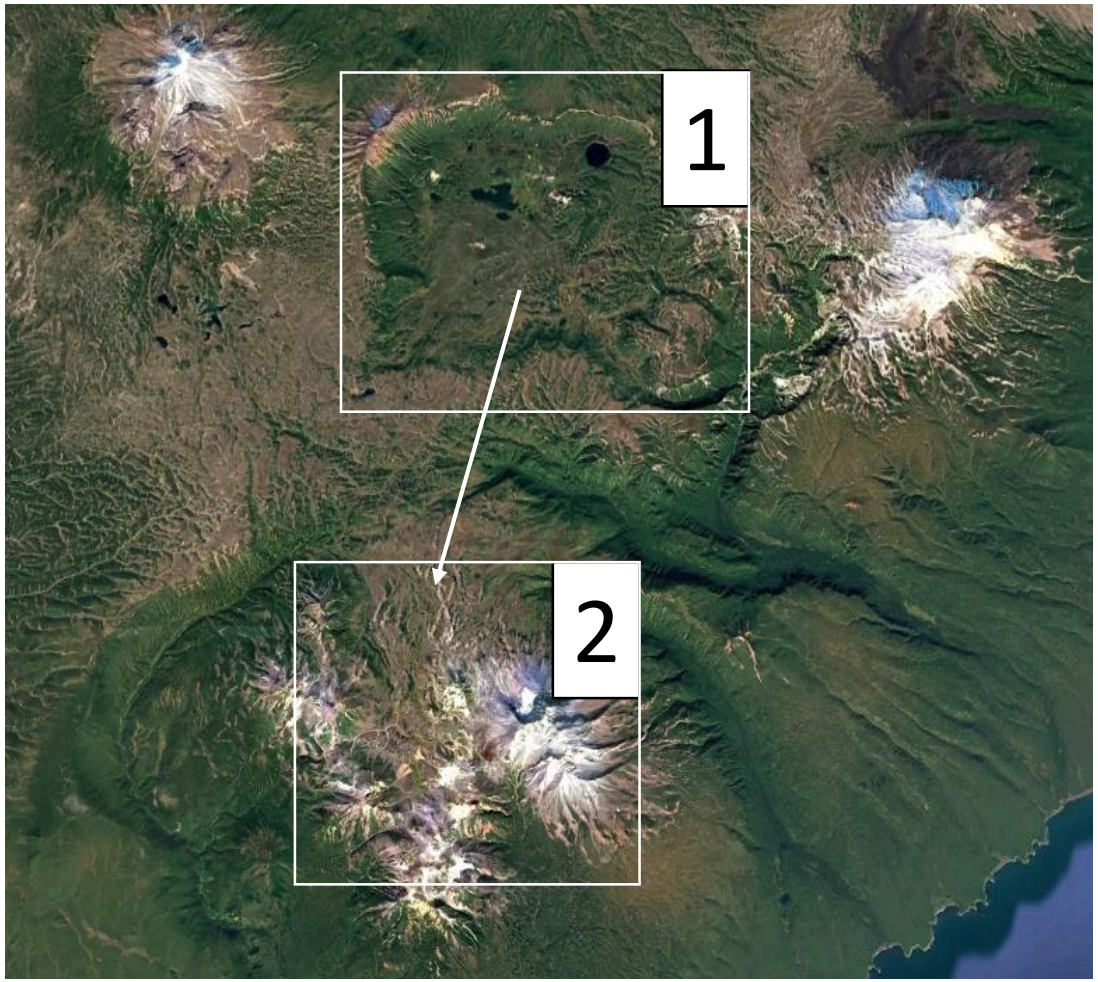
Актуальность и цель исследования

- Искусственный интеллект (Artificial Intelligence, AI) выступает в качестве общей рамки, объединяющей все подходы к автоматизированному дешифрированию с помощью данных ДЗЗ;
- Машинное обучение (Machine Learning, ML) представляет собой набор методов, в рамках которого модель обучается на данных. Оптимален для задач с определенными спектральными признаками (спектральные каналы, индексы, морфология рельефа). В докладе будет рассмотрено машинное обучение с учителем;
- Глубокое обучение (Deep Learning, DL) является подразделом машинного обучения, основанным на многослойных нейросетях. Используется, когда объекты определяются формой, текстурой и контекстом, а не только спектром.

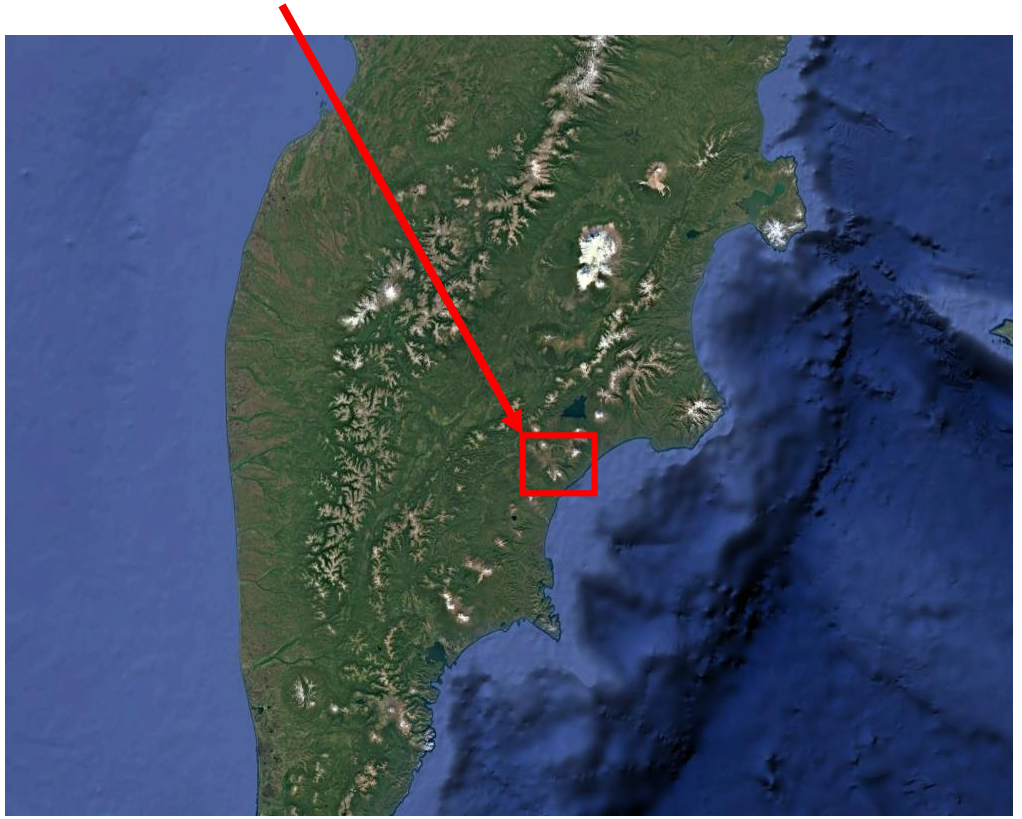


Иерархия методов искусственного интеллекта

Территория исследования 1

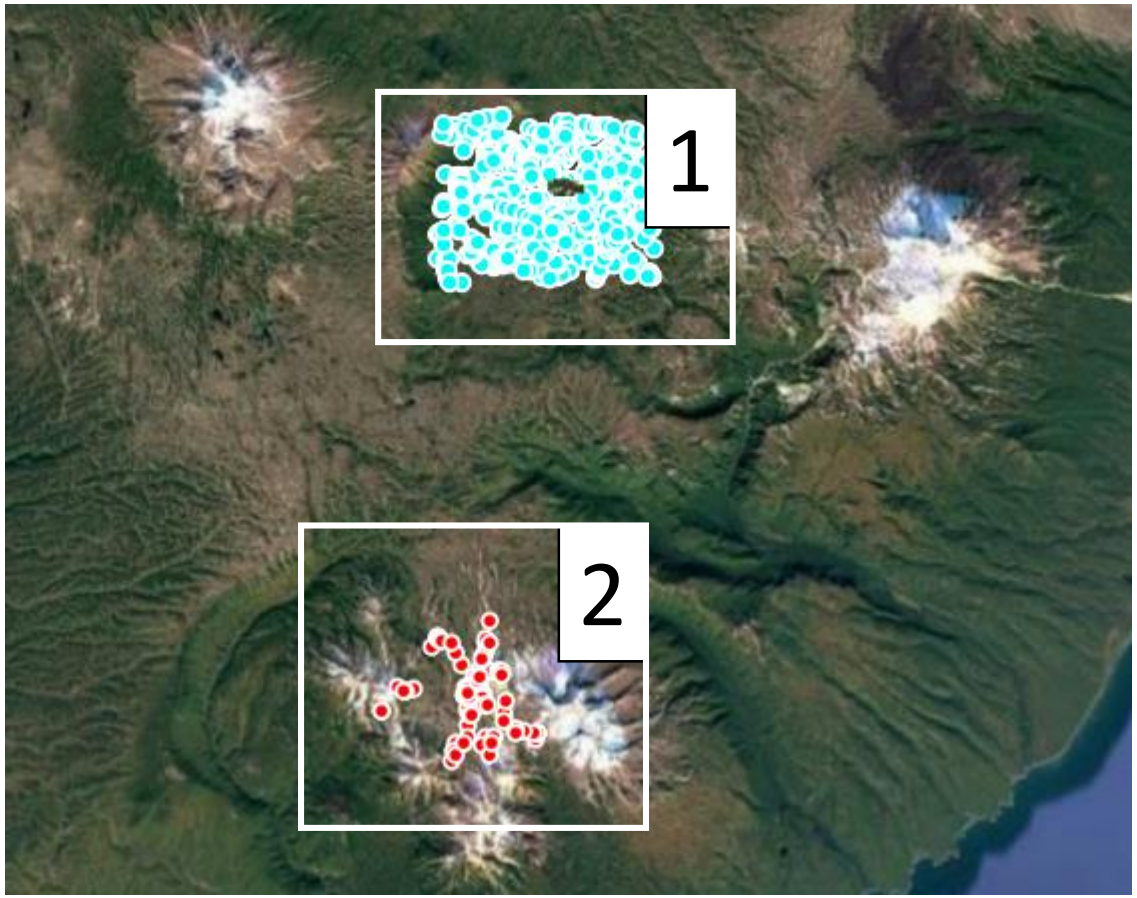


Местонахождение кальдер
Узон и Бурлящего



1 – кальдера Узон
2 – кальдера Бурлящего

Полевые данные и их обработка (Кроноцкий заповедник)
Геоботанические описания



1 – кальдера Узон (около 1 тыс. точек)
2 – кальдера Бурлящего (около 40-50 точек)

class_14_tochki_all_data — объектов всего: 2374, отфильтровано: 2374, выбрано: 0

	Plot	pp	FIELD_NR	CLASS	TYPE_PCA	index	class_name	class_new	VEG_TYPE	Database	Lat	Lon	Cor
1	1	1	BR107	NULL	Stlanik	St.a	olxovyy stlanik	olxovyy stlanik	Stlanik	Pesterov	54,34157000000	159,933420000...	OK
2	2	2	BR105	NULL	Stlanik	St.a	olxovyy stlanik	olxovyy stlanik	Stlanik	Pesterov	54,29869000000	159,942590000...	OK
3	3	3	BR116	NULL	Stlanik	St.a	olxovyy stlanik	olxovyy stlanik	Stlanik	Pesterov	54,34044000000	159,963010000...	OK
4	4	4	BR115	NULL	Stlanik	St.p	kedrovyy stlanik	kedrovyy stlanik	Stlanik	Pesterov	54,34132000000	159,963070000...	OK
5	65	65	BR100	NULL	Tundra	T.m	kyst_tundra	tundra	Tundra	Pesterov	54,31603000000	159,952370000...	OK
6	66	66	BR101	NULL	Tundra	T.m	kyst_tundra	tundra	Tundra	Pesterov	54,31783000000	159,951480000...	OK
7	67	67	BR103	NULL	Tundra	T.m.l	lishainik_tundra	tundra	Tundra	Pesterov	54,31145000000	159,952420000...	OK
8	68	68	BR104	NULL	Pioneer	Pnr	pioner	pioner	Pioneer	Pesterov	54,30191000000	159,943780000...	OK
9	69	69	BR108	NULL	Tundra	T.m.l	lishainik_tundra	tundra	Tundra	Pesterov	54,34248000000	159,933910000...	OK
10	70	70	BR109	NULL	Pioneer	Pnr	pioner	pioner	Pioneer	Pesterov	54,33900000000	159,930000000...	OK
11	71	71	BR111	NULL	Tundra	T.m.l	lishainik_tundra	tundra	Tundra	Pesterov	54,30791000000	159,992490000...	OK
12	72	72	BR112	NULL	Tundra	T.m.l	lishainik_tundra	tundra	Tundra	Pesterov	54,30974000000	159,980490000...	OK
13	73	73	BR113	NULL	Tundra	T.m	kyst_tundra	tundra	Tundra	Pesterov	54,31594000000	159,900000000...	OK
14	74	74	BR114	NULL	Tundra	T.m.l	lishainik_tundra	tundra	Tundra	Pesterov	54,32449000000	159,909620000...	OK
15	75	75	BR91	NULL	Tundra	T.m	kyst_tundra	tundra	Tundra	Pesterov	54,32470000000	159,951040000...	OK
16	76	76	BR93	NULL	Pioneer	Pnr	pioner	pioner	Pioneer	Pesterov	54,32213000000	159,948940000...	OK
17	77	77	BR94	NULL	Pioneer	Pnr	pioner	pioner	Pioneer	Pesterov	54,32092000000	159,950930000...	OK
18	78	78	BR95	NULL	Tundra	T.m	kyst_tundra	tundra	Tundra	Pesterov	54,32050000000	159,952580000...	OK

Все объекты

Активация Windows

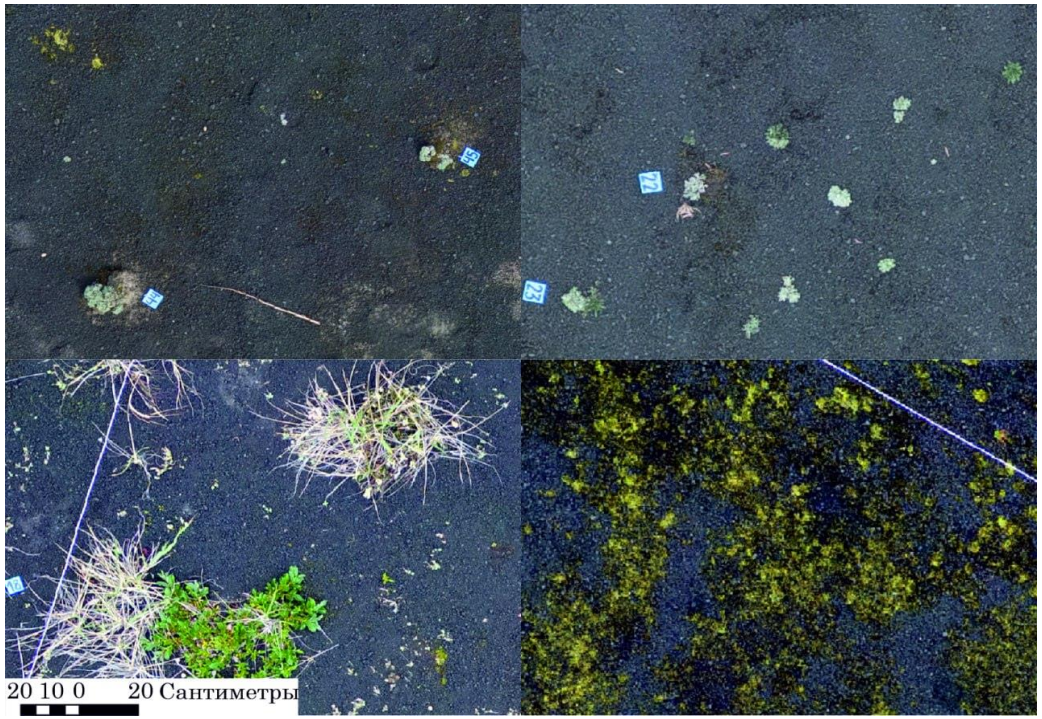
Создание системы классов исходя из доступных данных ДЗЗ

Конечный перечень классов включает:

1) ольховый стланик
2) кедровый стланик
3) горные кустарничковые тундры
4) лишайниковые тундры
5) растительность на осыпях
6) болота (низинные и переходные)
7) термальная растительность
8) березняки
9) водные объекты
10) снег

Полевые данные и их обработка (Тоблачинский дол)
Геоботанические описания

- В программе Agisoft Metashape было создано 40 ортофотопланов.
- Классы: «светлая» голая земля; «тёмная» голая земля; сосудистые растения, а также мхи, поделённые на более светлые и темные, в зависимости от их отображения на ортофотоплане.

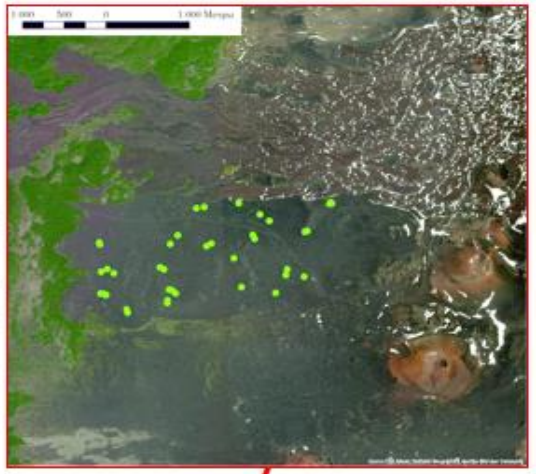


Характерная для Толбачинского дола несомкнутая растительность (группировки) на ортофотопланах



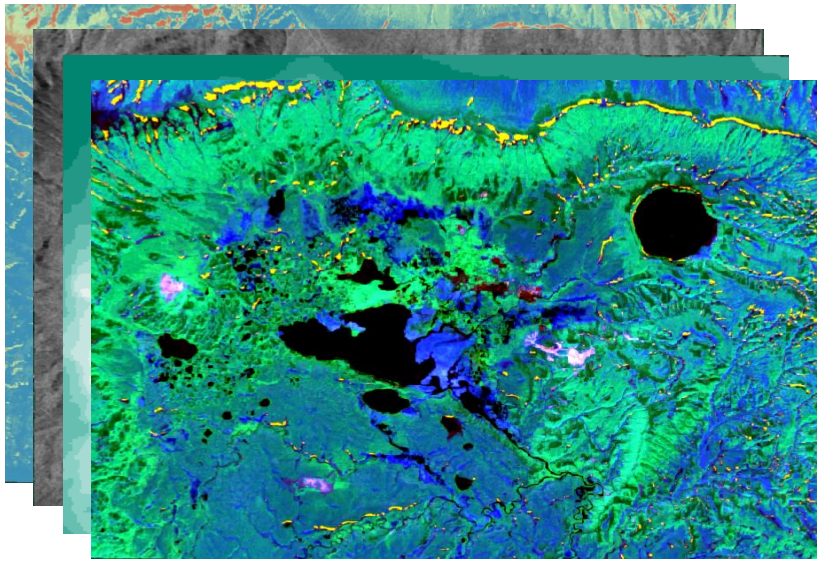
Пример обучающей выборки

Область исследования (Зелеными точками отмечены месторасположения пробных площадей, на которые были сделаны ортофотопланы).



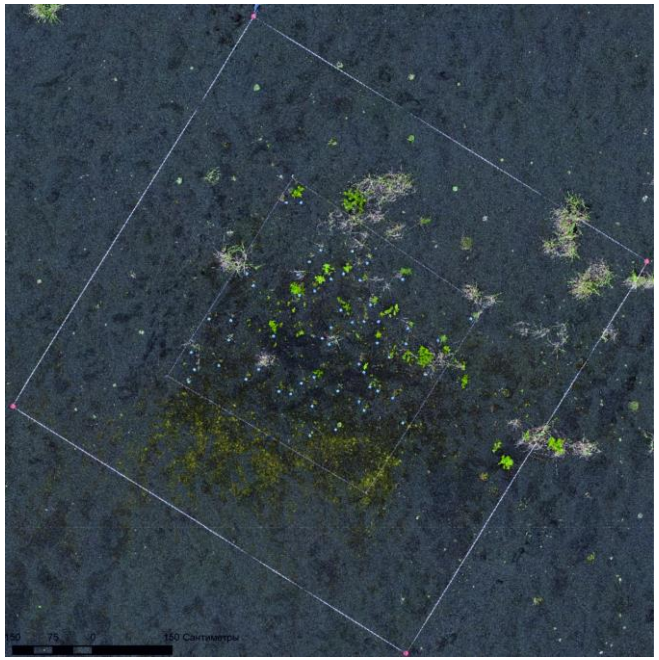


Данные дистанционного зондирования, используемые в работе



1) Кальдера Узон и Бурлящий:

- Оптические данные: мультиспектральные снимки (Sentinel-2, Landsat) и производные от них индексы;
- Радиолокационные данные (Sentinel-1);
- Температурные данные;
- Морфометрические данные;
- Биофизические данные;
- Текстурные признаки на основе скользящего окна.



2) Толбачинский дол:

40 RGB-ортофотопланов разрешением примерно 2-3 сантиметра площадью около 10 на 10 метров.

Оценка точности моделей

- Accuracy - доля правильных ответов алгоритма от всех возможных ответов. Самый неиспользуемый и неинформативный показатель, который, однако, служит хорошей метрикой для оценки параметров модели. Рассчитывается по формуле:

$$\boldsymbol{accuracy} = \frac{\boldsymbol{TP} + \boldsymbol{TN}}{\boldsymbol{TP} + \boldsymbol{TN} + \boldsymbol{FP} + \boldsymbol{FN}}$$

- Precision - доля истинно положительных результатов ко всем положительным результатам, предсказанным классификатором. Можно интерпретировать как долю объектов, названных классификатором положительными и при этом действительно являющимися положительными. Рассчитывается по формуле:

$$\boldsymbol{precision} = \frac{\boldsymbol{TP}}{\boldsymbol{TP}+\boldsymbol{FP}}$$

- Recall (полнота) - доля истинно положительных результатов ко всем положительно размеченным моделью данным. Можно интерпретировать как способность модели обнаруживать истинно тот или иной класс среди всех положительно отнесенных к этому классу объектов. Рассчитывается по формуле:

$$\boldsymbol{recall} = \frac{\boldsymbol{TP}}{\boldsymbol{TP}+\boldsymbol{FN}}$$

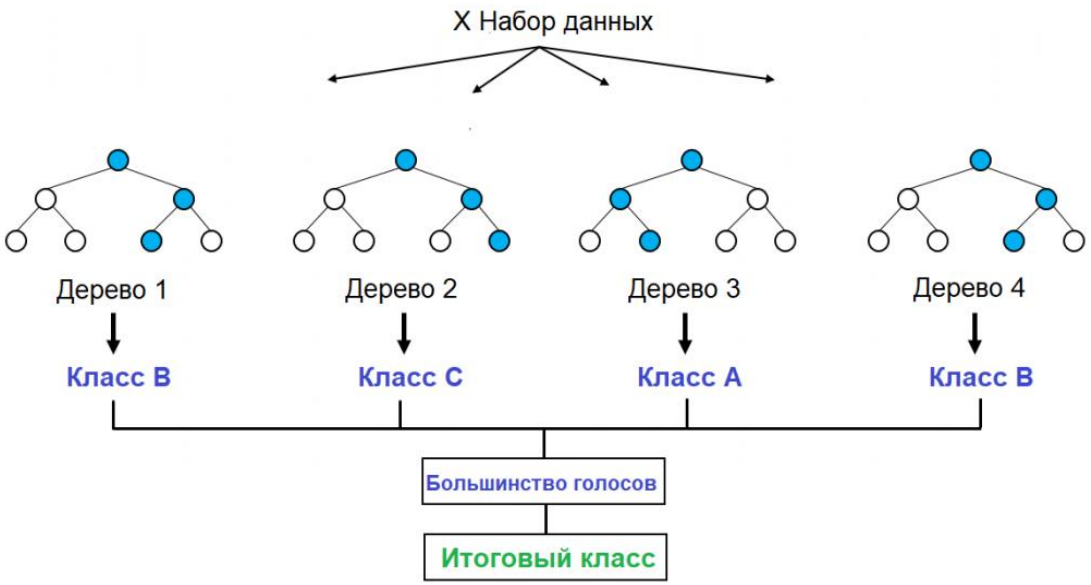
- F1-score – среднее гармоническое между recall и precision. Показывает то, насколько похоже размечали данные авторы и модель. Рассчитывается по формуле:

$$\boldsymbol{f1-score} = \frac{\boldsymbol{2 * precision * recall}}{\boldsymbol{precision} + \boldsymbol{recall}}$$

Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

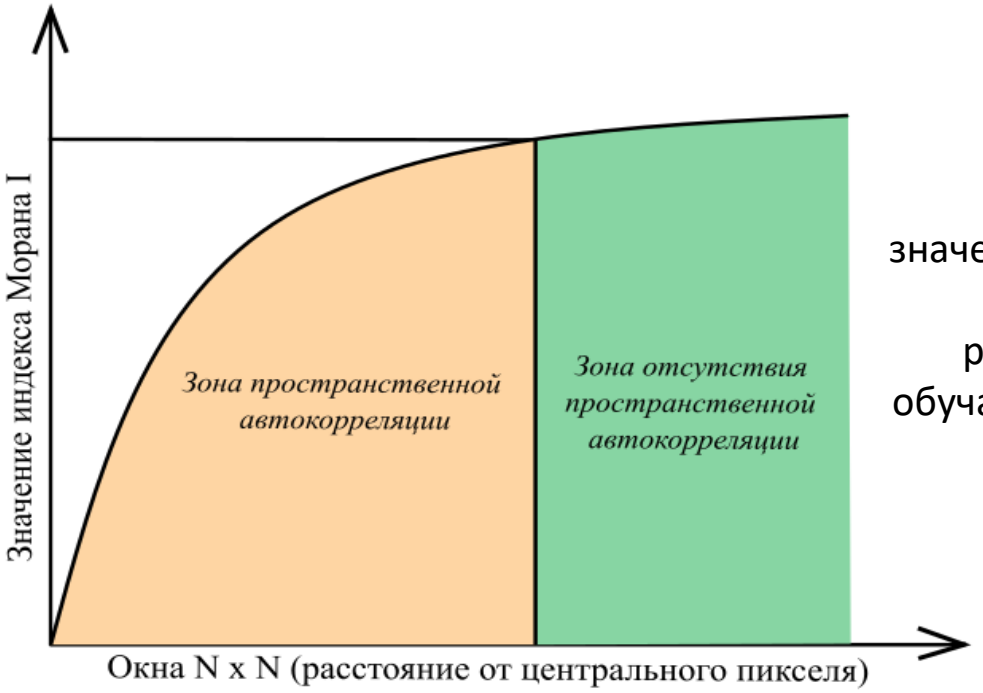
Апробация алгоритма Случайного леса для кальдеры Узон



Принцип работы Случайного леса

Примечания:

- Подбор гиперпараметров модели осуществлялся с помощью RandomizedSearchCV в Python;
- Осуществлялась кросс-валидация с учетом пространственной автокорреляции для объективной оценки модели.



Кривая зависимости значения индекса Морана I от расстояния от обучающей точки

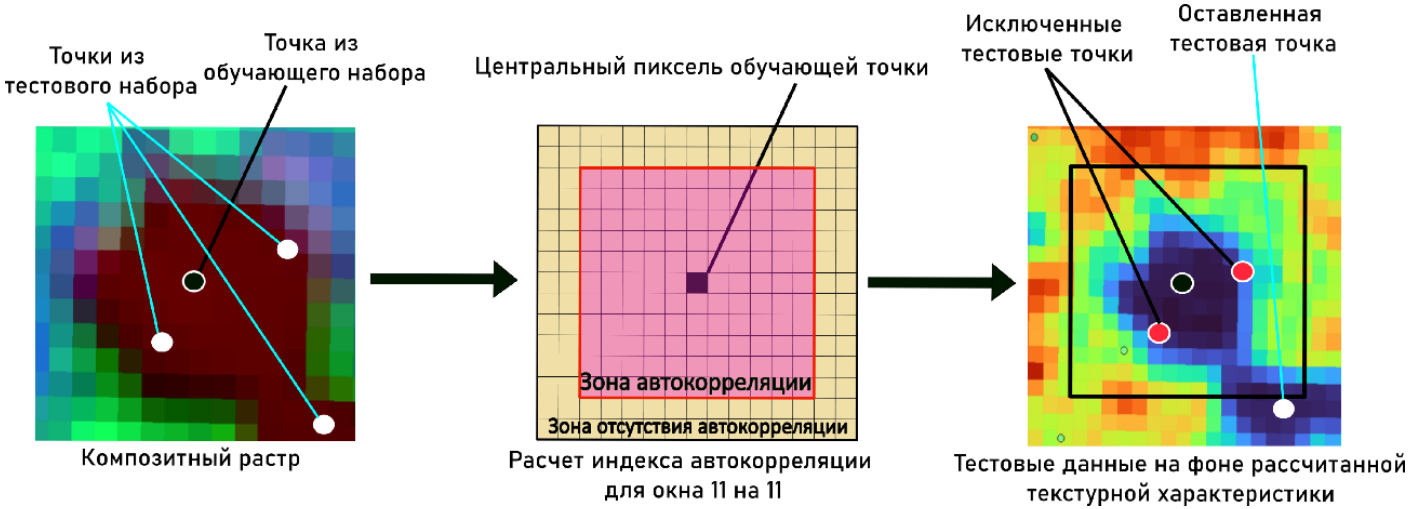
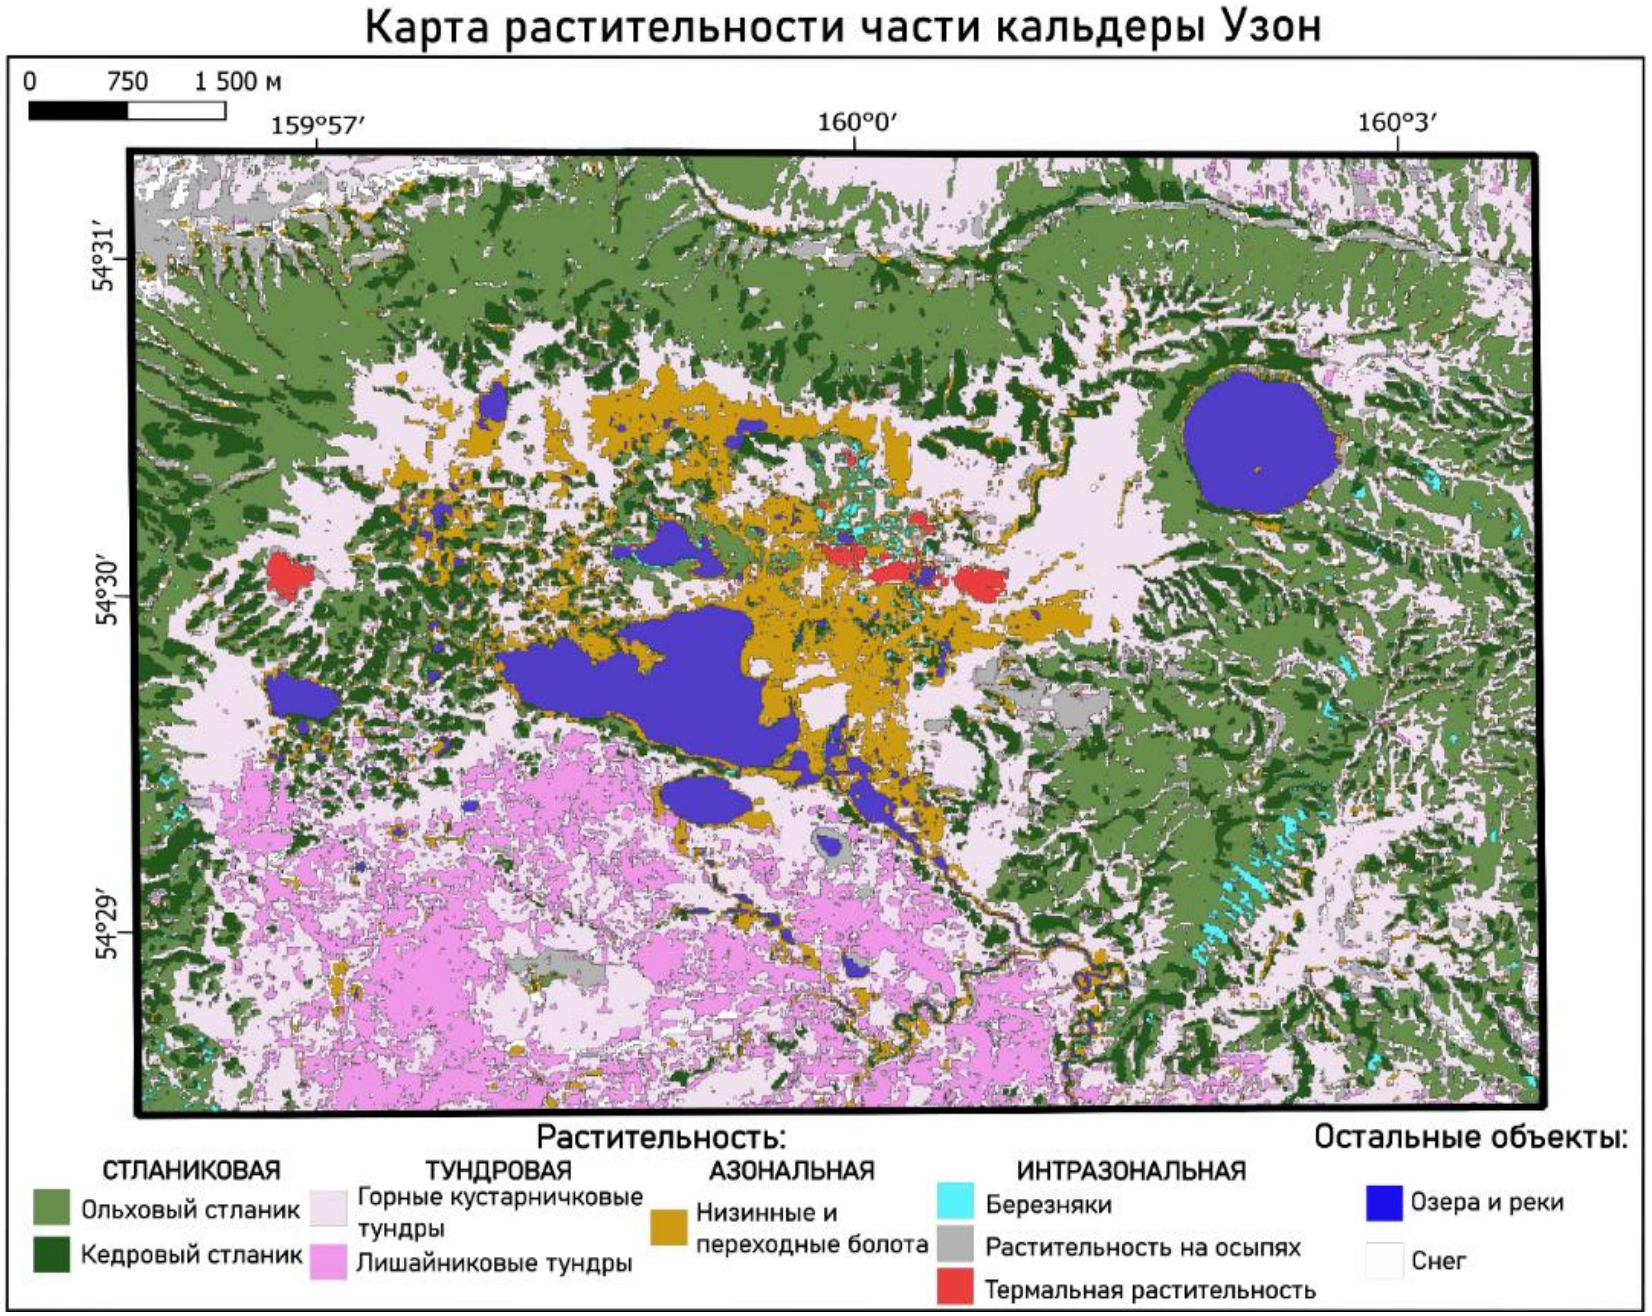


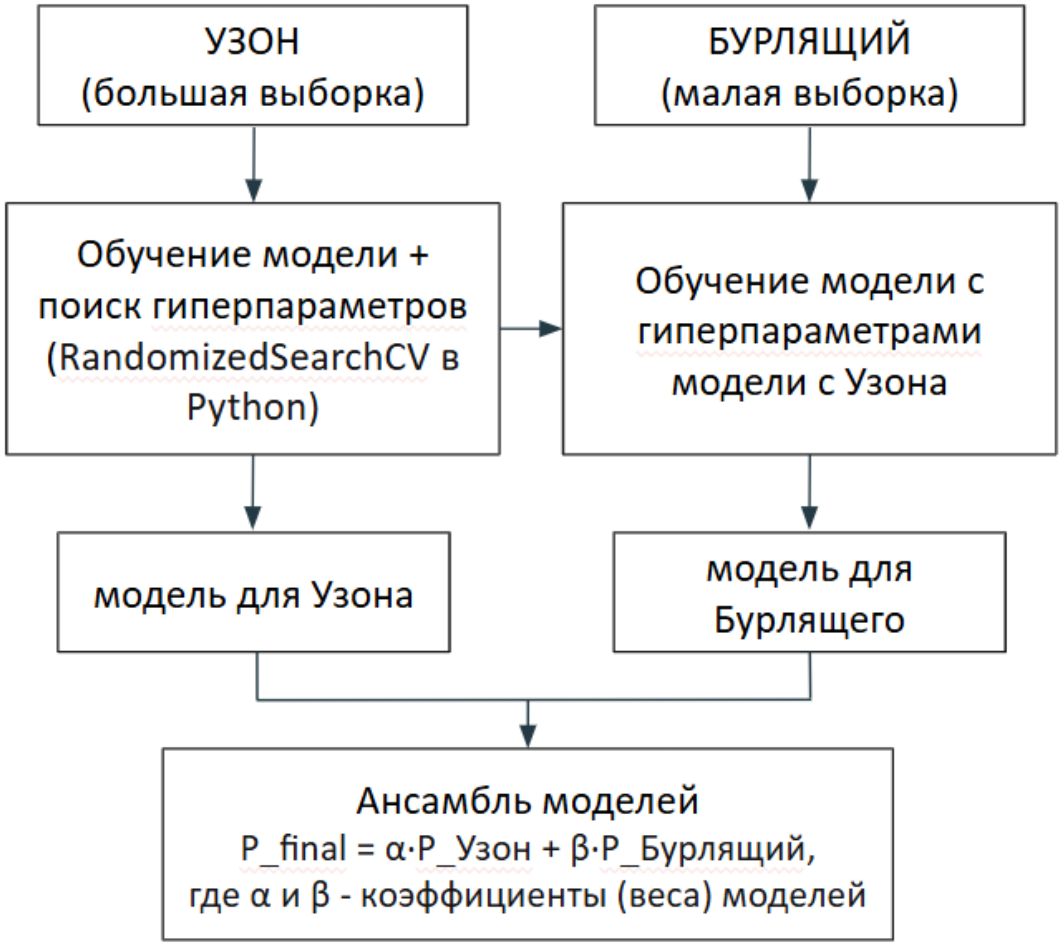
Схема использования индекса Морана I для предобработки тестовых данных и создания дополнительных текстурных признаков

Результат применения Случайного леса для кальдеры Узон:

F1 = 0,89

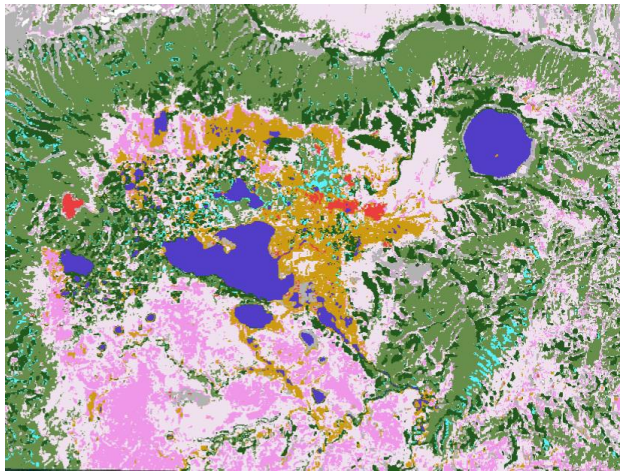


Переносимость алгоритма Случайного леса для кальдеры Бурлящего

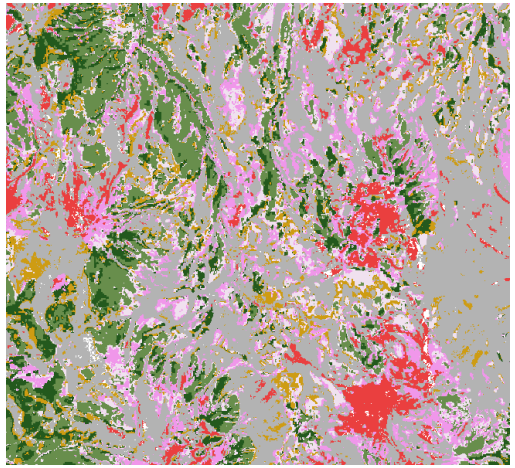


Общая схема ансамбля моделей Случайного леса для кальдеры Бурлящего

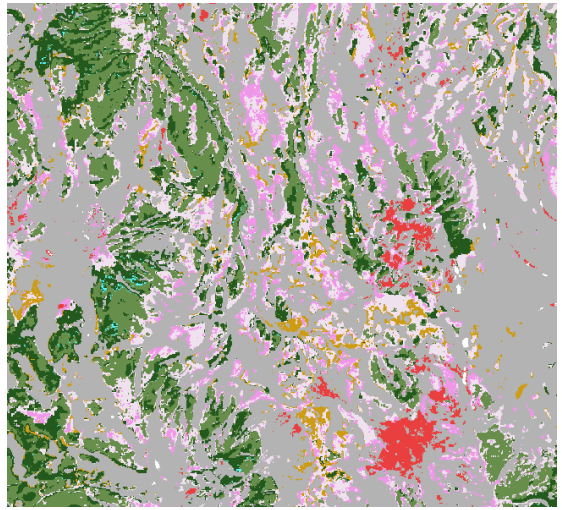
Результат применения Случайного леса для кальдеры Бурлящего



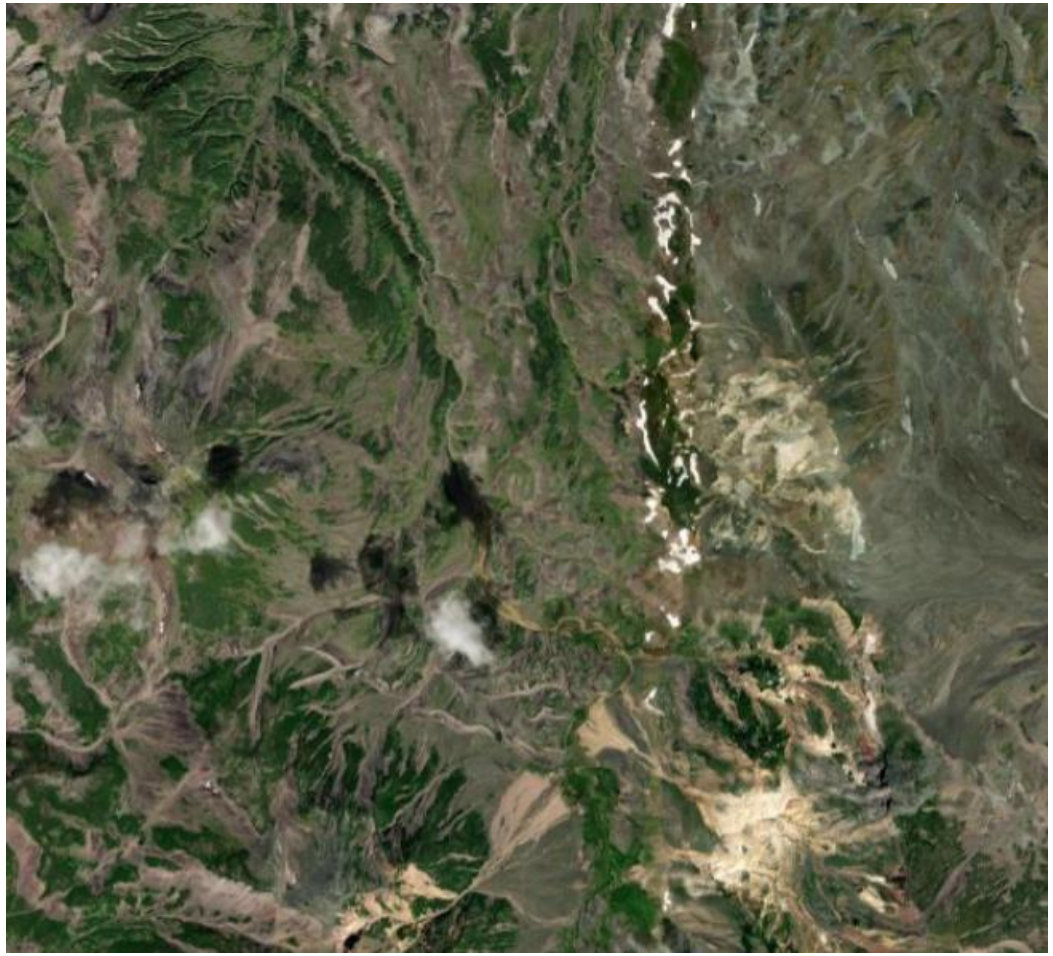
Модель RF, обученная на Узоне с учетом пространственной автокорреляции
F1 = 0,89



Модель RF, обученная на малом количестве данных на Бурлящем
F1 = 0,71

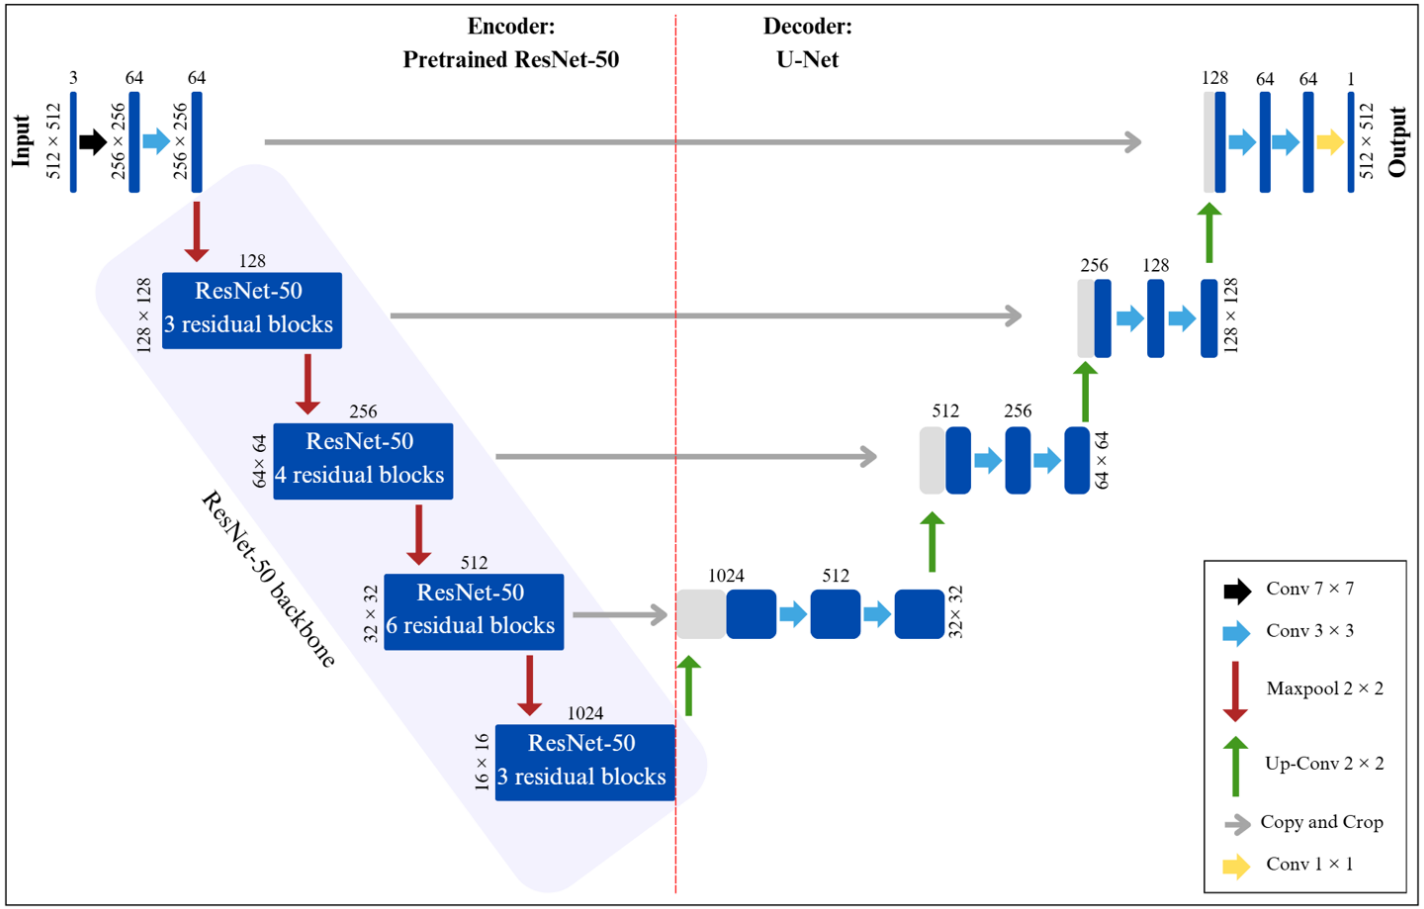


Ансамбль моделей Узона и Бурлящего
F1 = 0,79

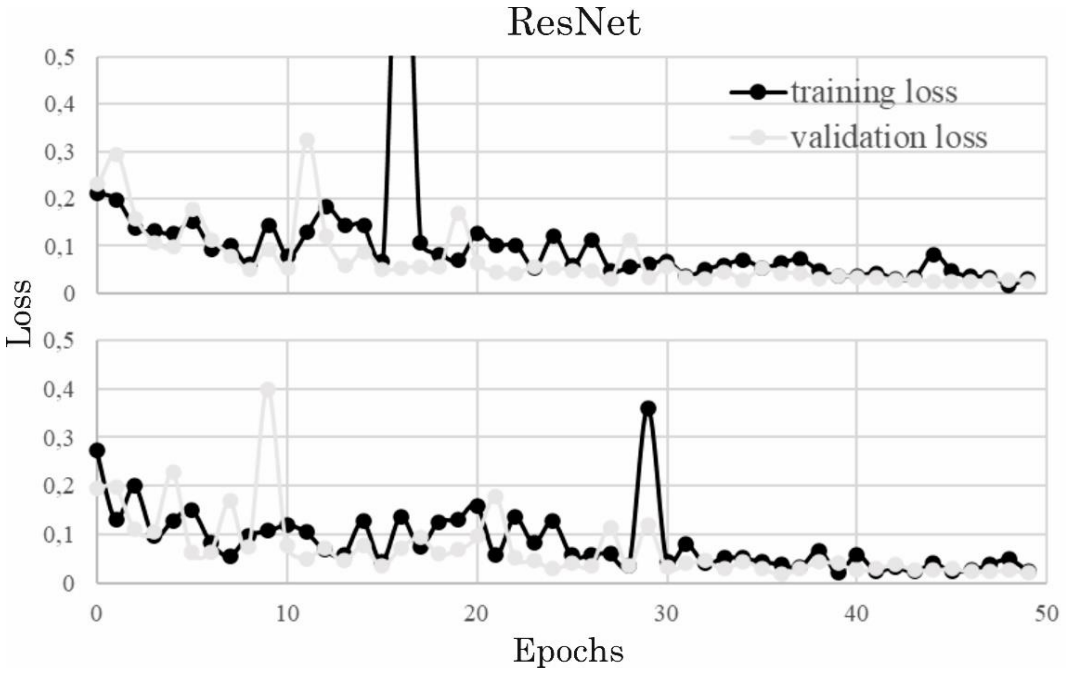


Снимок кальдеры Бурлящего, взятый из Google Earth Pro

Предобученная нейросетевая архитектура U-Net



Общая схема строения архитектуры U-Net с предобученными весами ResNet (в основе - ImageNet)

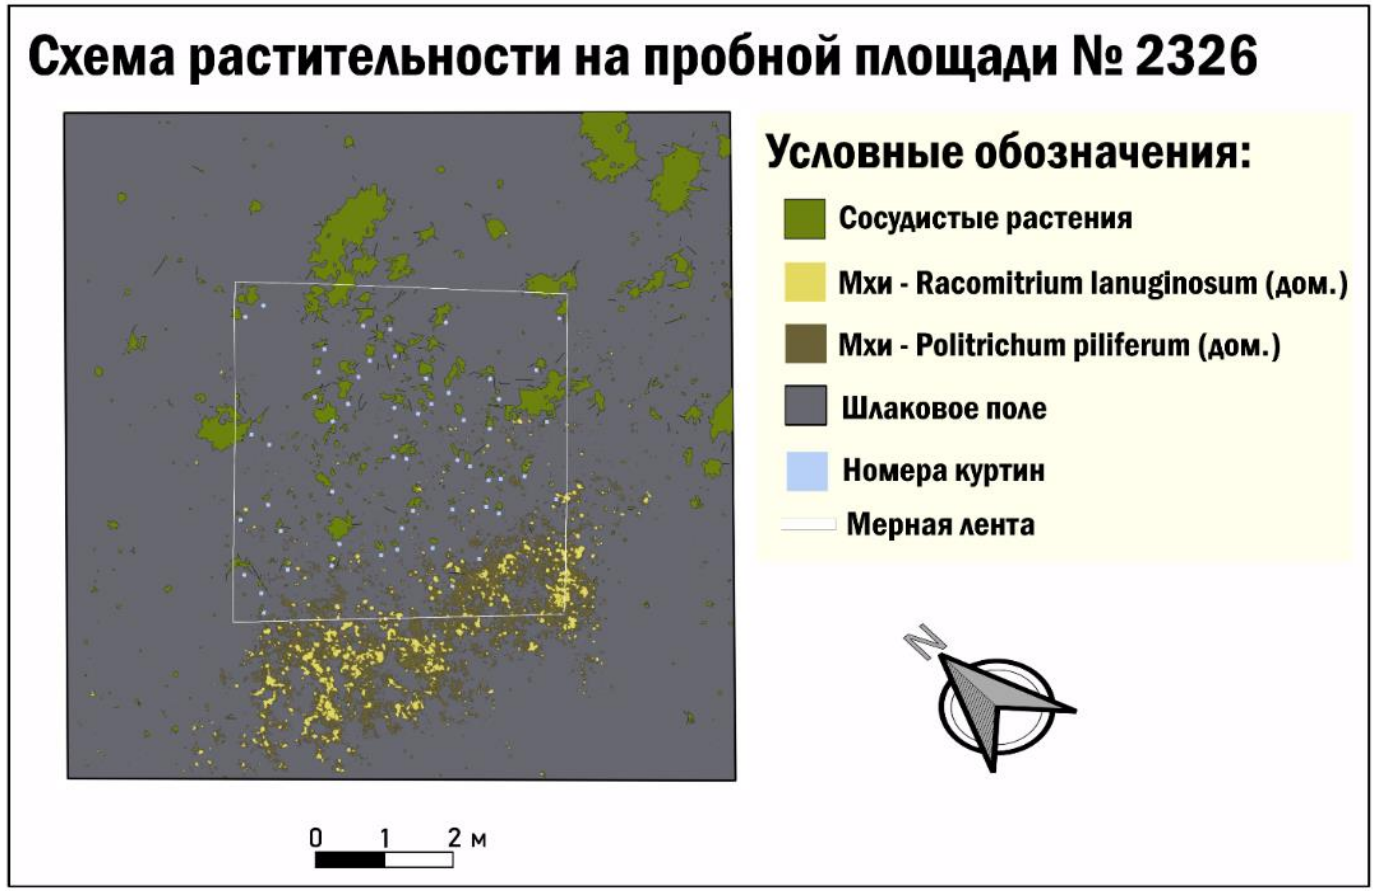


Графики validation и training loss для «остаточных» CNN ResNet-18 (снизу) и ResNet-34 (сверху)

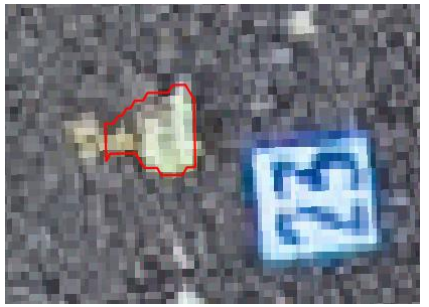
Вывод: при наличии четких границ и «простых» классов или объектов сегментации глубокая нейросеть не нужна.

Применение нейросетевой модели на основе архитектуры U-Net, обученной на двух ортофотопланах

Схема растительности, созданная на основе нейросети



Средняя точность для ортофотопланов (F1-score = 0.85)









Сравнение выделений растения с помощью нейросети (левые примеры) и силами сотрудников БИН РАН (правые примеры)

Выводы:

1. Ансамбль моделей случайного леса повышает устойчивость прогнозов при переносе между кальдерами по сравнению с использованием единственной модели (F1 вырос с 0,71 до 0,79), но важно соблюдать географическую схожесть территорий картографирования.

2. Исключение классов, отсутствующих на новом участке, — один из способов адаптации модели случайного леса без переобучения модели заново.

3. Fine-tuning U-Net с энкодером ResNet, предобученным на ImageNet, даёт высокие метрики на ортофотопланах (средний F1 = 0,85, Kappa > 0,8), но важно заметить, что существует склонность модели пропускать растительность, а не ошибаться ложными срабатываниями, а также что мелкие и нечёткие объекты (мхи, тонкие листья) распознаются хуже.

4. При переносе U-Net с одного ортофотоплана на другой (обучение на 2 из 40) более глубокая сеть (ResNet-34) не дала значимого преимущества перед ResNet-18. Можно сделать вывод о том, что на малой выборке сложные энкодеры избыточны.

5. Случайный лес и U-Net решают разные задачи:

случайный лес — классификация пикселов по спектральным признакам (спутниковые снимки);

U-Net — сегментация по форме/текстуре (на основе снимков с дрона).

6. Необходима адаптация моделей машинного обучения: ансамблирование, обрезка классов (для случайного леса) или fine-tuning на небольшом количестве данных (для U-Net), при этом, для примера с Толбачинским Долом учёт пространственной автокорреляции относительно неважен.

Спасибо за внимание!

