

Распознавание типов нарушений лесного покрова с применением методов машинного обучения

Тарасов А.В.¹, Канев А.И.², Шихов А.Н.¹, Подопригорова Н.С.², Сафонов Ф.А.²

¹ Пермский государственный университет, Пермь, Россия

² МГТУ им. Н.Э. Баумана

Исследование выполнено при поддержке РФФ, проект № 22-27-20018

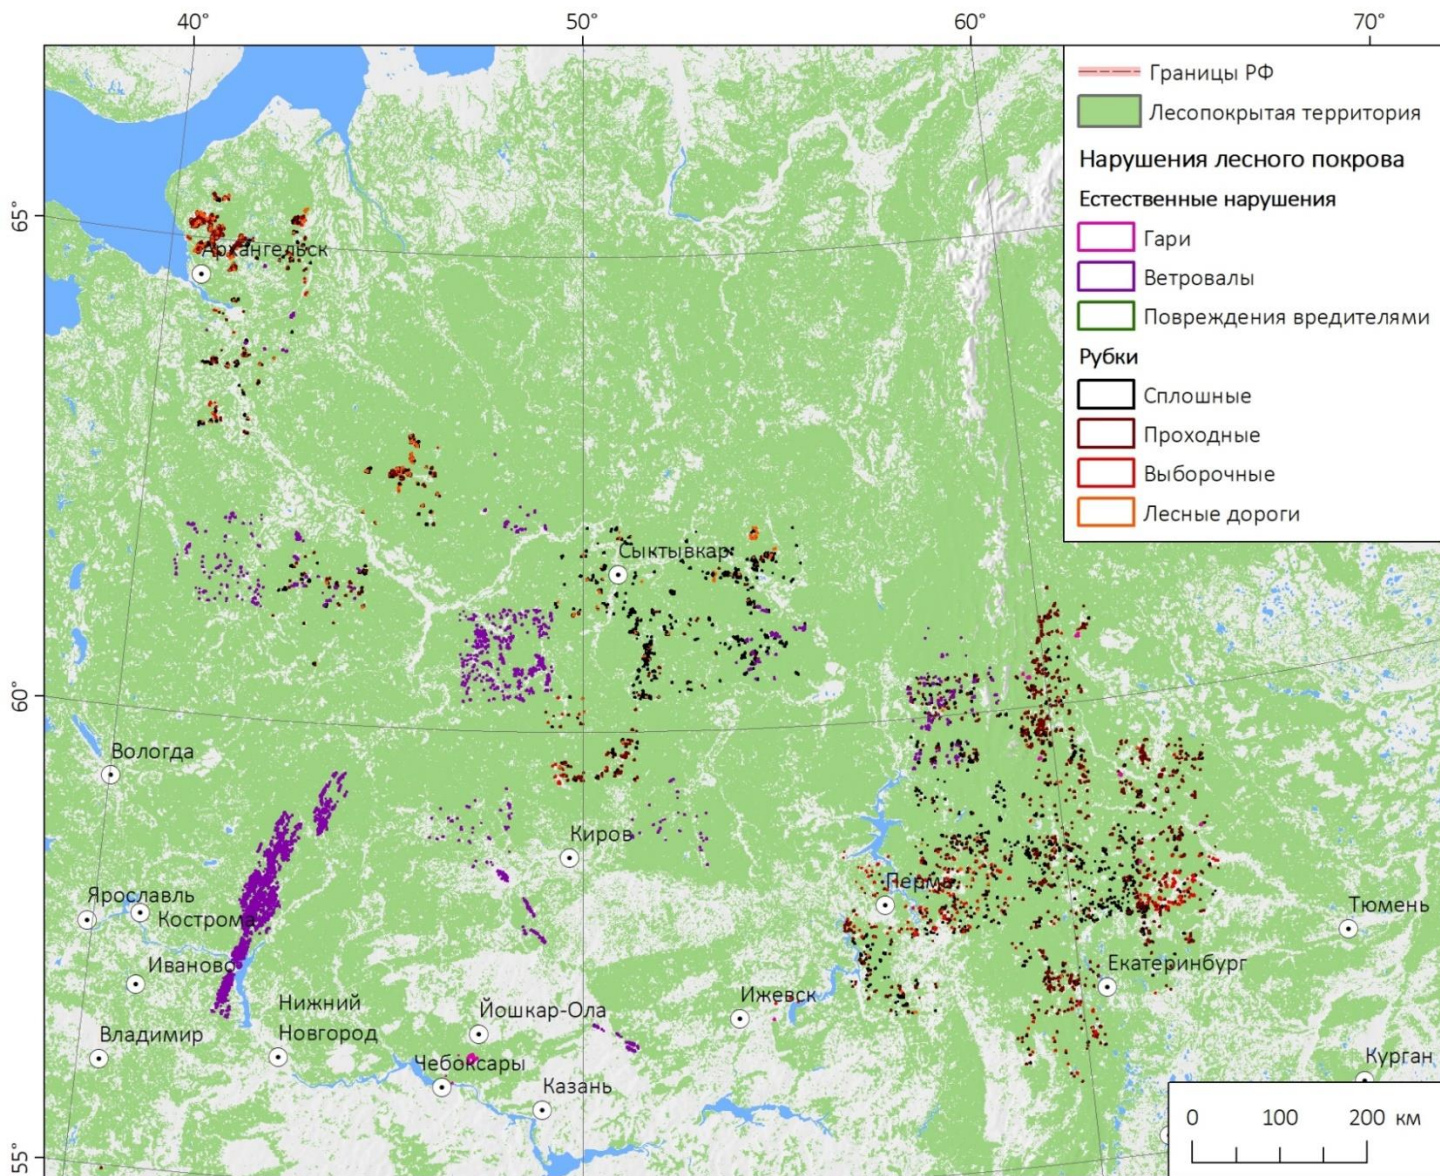
Актуальность и цель исследования

- В настоящее время спутниковый мониторинг обеспечивает получение в автоматическом режиме данных о площади повреждений лесов с приемлемым пространственным разрешением и точностью (см. напр. Global Forest Change). Однако **определение причин нарушений** (классификация по типам: вырубки, гари, ветровалы, повреждения вредителями и болезнями), **как правило, не автоматизировано**. Решение этой задачи позволит получить важную информацию для оценки углеродного баланса, влияния разных типов нарушений на биоразнообразие, экономических последствий, и для совершенствования управления лесными ресурсами.
- **Цель исследования** – оценить возможность распознавания типов нарушений лесного покрова по снимкам Sentinel-2 с применением алгоритмов машинного обучения.

Последовательность выполнения

- **Разметка обучающей выборки (17775 объектов разных классов).** Для каждого объекта определены тип, даты появления, идентификаторы снимков
- Предобработка данных для использования в моделях машинного обучения
- Эксперименты со сверточной нейронной сетью U-net по мультиклассовой и бинарной сегментации объектов (А.В. Тарасов)
- Эксперименты с алгоритмами XGBoost, Random Forest и U-net по бинарной классификации различных типов повреждений лесного покрова (А.В. Канев с соавторами)
- **Перспектива**
- Решение проблемы повышения точности мультиклассовой сегментации
- Оценка влияния внешних факторов (породный состав и возраст насаждений, уклон), а также сезона съемки на точность распознавания нарушений и их типов



Обучающая выборка



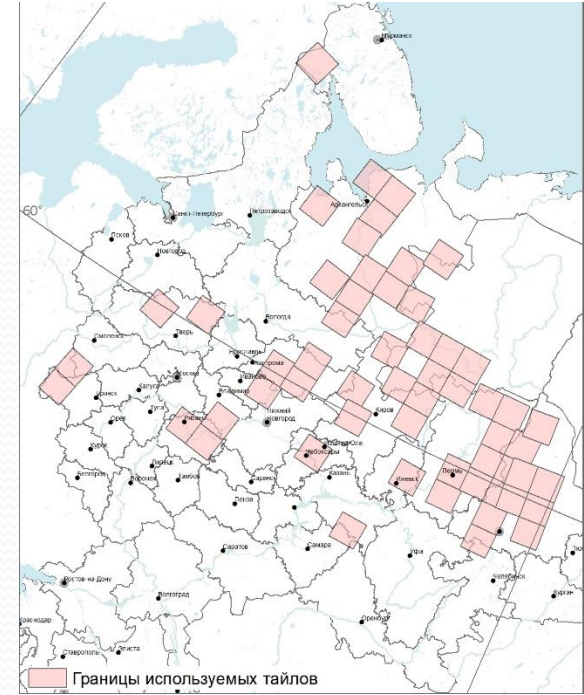
- Общий объем: 17765 объектов
- 2523 сплошных рубок
- 2981 проходных рубок
- 544 выборочные рубки
- 721 лесных дорог
- 10976 участков ветровала
- 20 гарей

Создание обучающей выборки и ее базовые характеристики


Пример объектов из обучающей выборки



Территория создания обучающей выборки



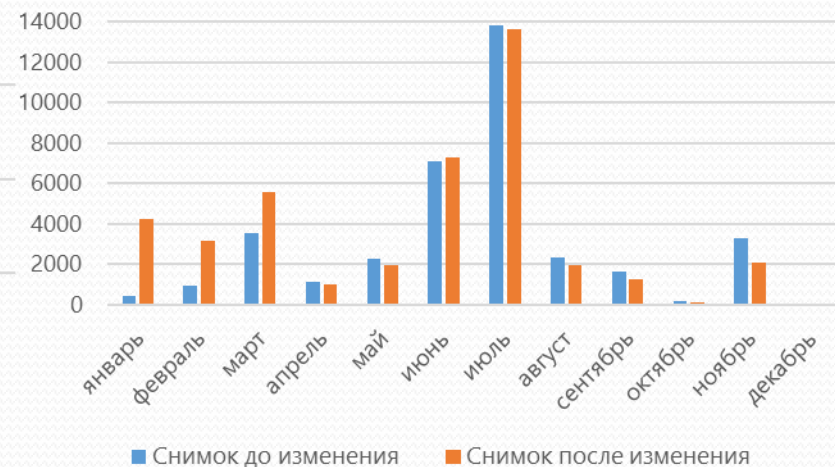
V выборки = **6790**
объектов (**17776** вместе с
ветровалами)



- Выборочная рубка
- Лесная дорога
- Проходная рубка
- Сплошная рубка

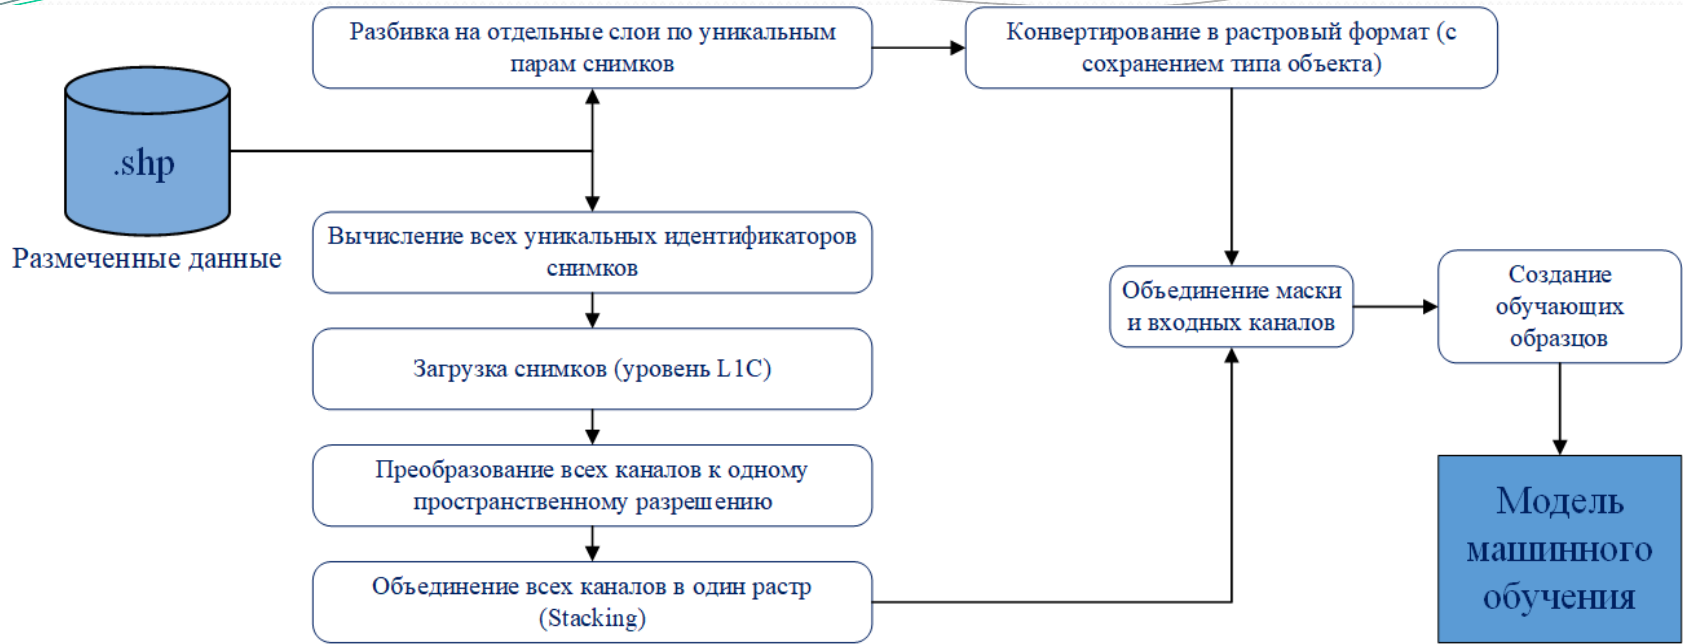
Распределение полученной выборки по типам

Всего данные по 57 тайлов Sentinel – 2
Временной диапазон - 26.01.2017 – 22.04.2022




- Снимок до изменения
- Снимок после изменения


Предобработка данных для обучения



Маска изменений



Красный канал до изменений



Красный канал после изменений





Пример полученного фрагмента для обучения

Информативные признаки для распознавания нарушений лесного покрова по снимкам Sentinel-2

- **Исходные значения яркости** в каналах B4 (Red), B8 (NIR), B11 (SWIR1) и B12 (SWIR2), по первому и второму снимку
- **Разности яркостей** в тех же каналах (Old - New)
- **Разности вегетационных индексов NDVI, SWVI, NBR**, рассчитанных по первому и второму снимкам (Old - New)
- Всего 20 признаков

Мультиклассовая сегментация нарушений

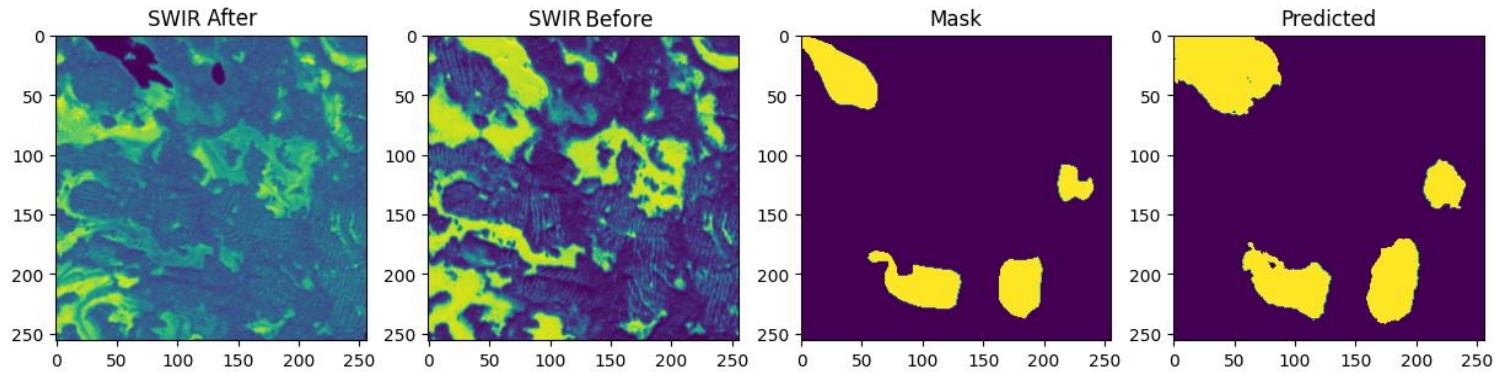
- Только антропогенные нарушения (сплошная рубка, выборочная, проходная рубка, лесная дорога)
- **Результат:** высокие значения потерь и низкая точность



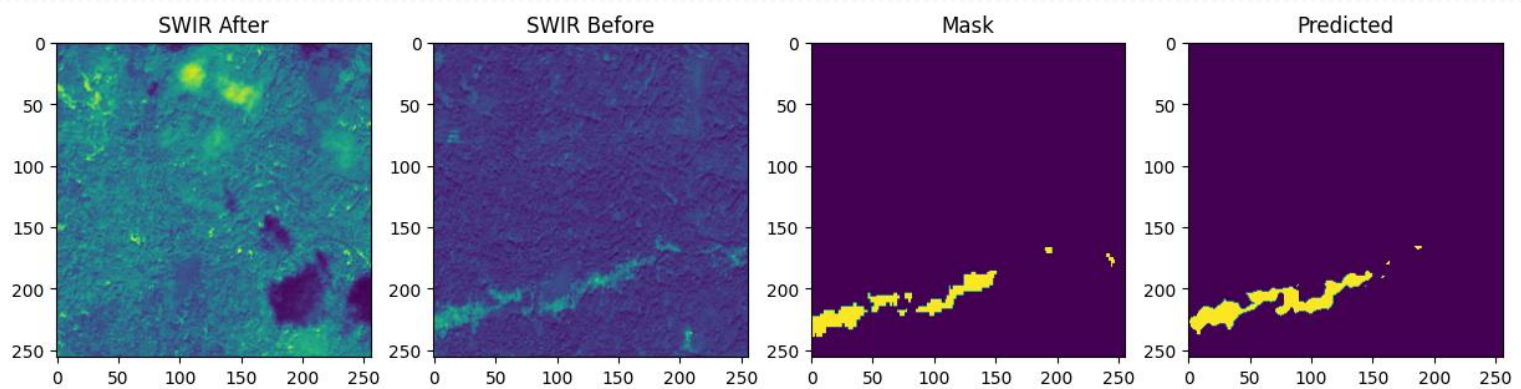
Альтернативные подходы

1. Бинарная классификация (нарушение или его отсутствие) + классификация выделенных нарушений другим алгоритмом
2. Обучение отдельных моделей под разные классы
3. Усложнение моделей + предобученные (backbone) модели


Пример бинарной классификации (проходная рубка)



Пример бинарной классификации (ветровал)




Пример бинарной классификации (гарь)



Распознавание сплошных и проходных рубок по снимкам разных сезонов, Архангельская область

- 2018.03.08 – 2018.07.31, синтез RGB



Автоматически выделенные контуры вырубок

Эксперименты с алгоритмом XGBoost

- **Данные для обучения** — 300 случайных тайлов из обучающей выборки, из них 150 — с объектами
- **Данные для тестирования** — 500 случайных тайлов (убраны из обучающей выборки).

Общие настройки для экспериментов: на вход модели бустинга подаются все 26 каналов, а также NDVI.

- **В первом эксперименте** результат оценивался без дальнейших преобразований.
- **Во втором эксперименте** использовались морфологические преобразования:
 - Закрытие. Эрозия, а затем расширение с параметрами эллипса 7, 7
 - Открытие. Расширение, а затем эрозия с параметрами эллипса 5, 5
 - Расширение с параметрами эллипса 10, 10
- **В третьем эксперименте** использовались фильтры для анализа текстуры по растру NDVI: фильтры Габор, Intensity, gradient intensity и local structure (всего 16 фильтров)

Морфологические операции и их результат

- **Операция закрытие:** эрозия, а затем расширение. Позволяет закрыть небольшие отверстия внутри объекта
- **Операция открытие:** расширение, а затем эрозия. Применяется для удаления шума.
- **Операция расширение.** Прямо противоположно эрозии. Пиксель будет равен «1», если хотя бы один пиксель в ядре равен «1». Применяется для соединения составных (сложных) объектов в один объект

Новый снимок



Старый снимок




Оригинальная маска



Предсказанная маска с МП



Предсказанная маска




Новый снимок



Старый снимок




Оригинальная маска



Предсказанная маска с МП





Предсказанная маска



Результаты экспериментов с алгоритмом XGBoost

- На графиках - результаты обучения XGBoost для эксперимента S2 – ошибка на тестовой и обучающей выборках



Эксперимент	Коэффициент Дайса
S1	0.49
S2	0.541
S3	0.428

Результаты Random Forest

- Были проведены аналогичные эксперименты, как и для XGBoost.
- Результаты трех экспериментов

Данные/Эксперимент	S1	S2	S3
300 тайлов (150 с объектами)	0.531	0.558	0.26

Эксперименты со сверточными нейронными сетями U-net

- Для тестирования модели выбран 251 образец
- На вход подавалось 16 каналов и разностей:
- $B4_{old}$, $B8_{old}$, $B4_{new}$, $B8_{new}$, $B4_{old} - B4_{new}$, $B4_{new} - B4_{old}$, $B8_{old} - B8_{new}$, $B8_{new} - B8_{old}$
- $B12_{old}$, $B12_{new}$, $B12_{old} - B12_{new}$, $B12_{new} - B12_{old}$
- $B11_{old}$, $B11_{new}$, $B11_{old} - B11_{new}$, $B11_{new} - B11_{old}$
- В экспериментах использовались следующие гиперпараметры: epoch = 230, lr = $1e^{-3}$, batch = 8

Оценка результатов




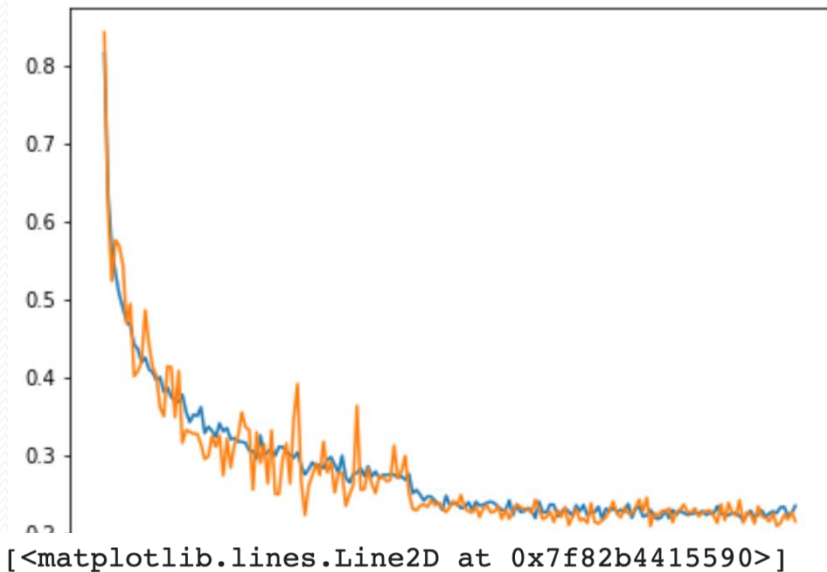
- **Использованные функции потерь**
- Бинарная кросс-энтропия
- Коэффициент Дайса
- Модификация коэффициента Дайса в виде функции потерь
- Индекс Тверского
- Комбинация коэффициента Дайса и бинарной кросс-энтропии
- **Метрики для оценки результата**

- Коэффициент Дайса

$$DC = \frac{2TP}{2TP + FP + FN} = \frac{2|X \cap Y|}{|X| + |Y|}$$

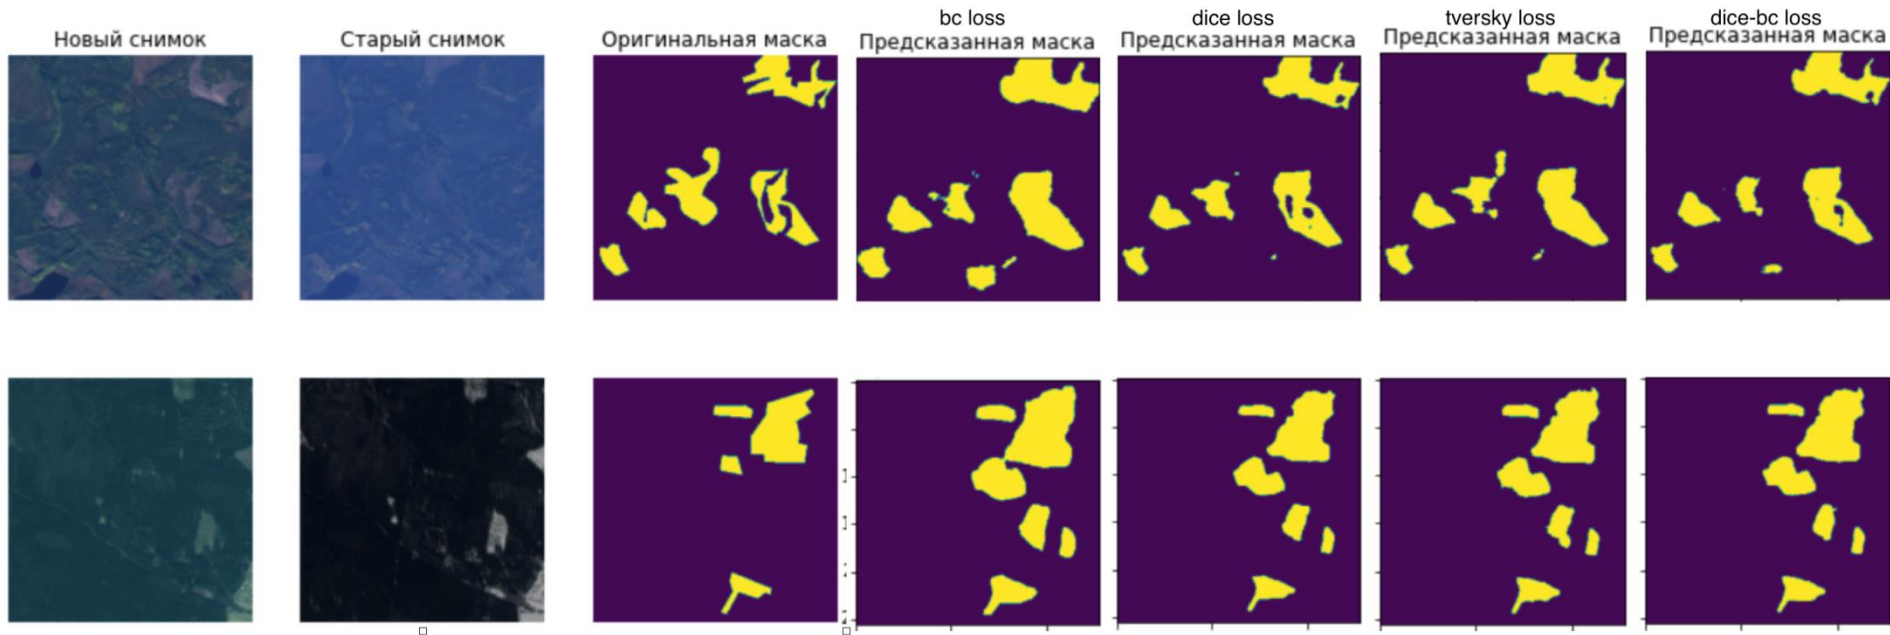
- где TP — истинные положительные результаты, FP — ложные положительные результаты и FN — ложные отрицательные результаты
- Индекс Жаккара или IoU (Intersection over Union)
- F-мера

Графики обучения при разных loss-функциях



Сравнение точности моделей U-net при разных loss-функциях

Функция потерь	Коэфф. Дайса	IoU	sensitivity	specificity	F-мера
Бинарная кросс-энтропия (БКЭ)	0.73	0.78	0.89	0.99	0.73
Коэфф. Дайса	0.79	0.82	0.79	1.00	0.79
Индекс Тверского	0.78	0.81	0.81	1.00	0.78
Коэфф. Дайса + БКЭ	0.78	0.81	0.79	1.00	0.78

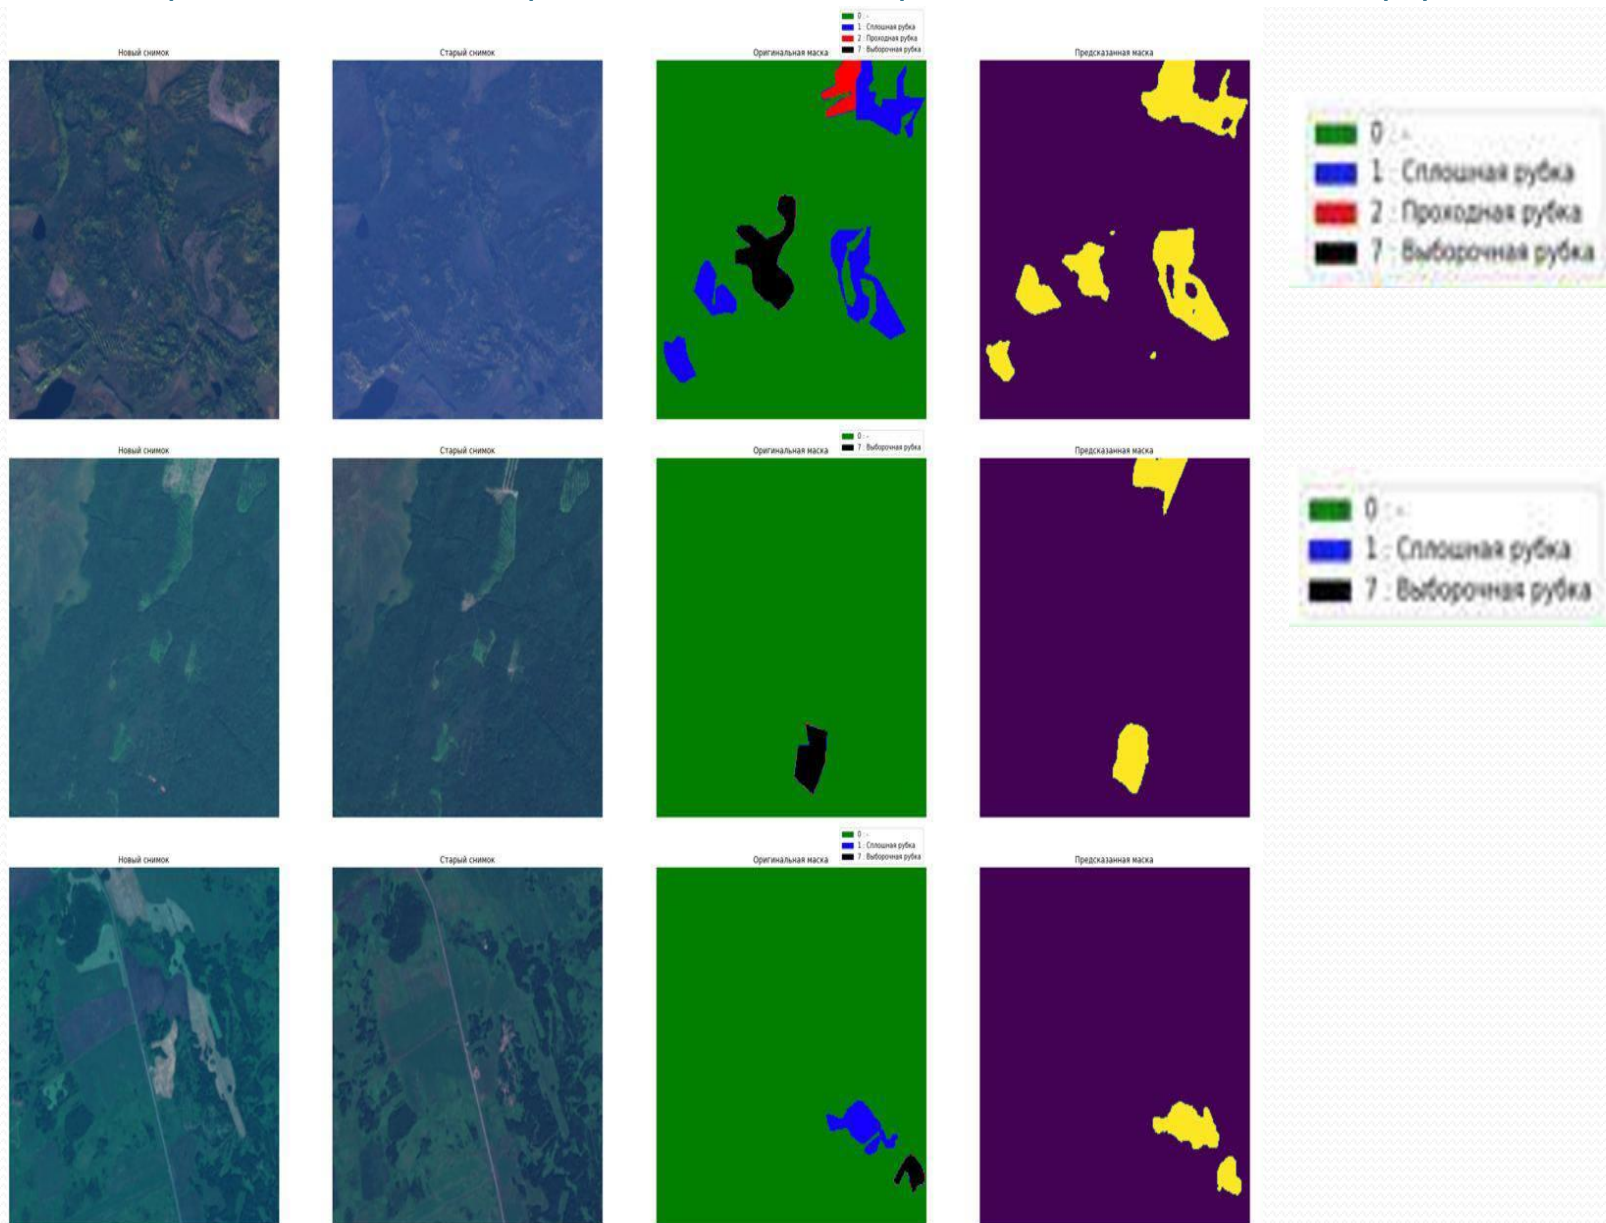


Эксперимент с разными сезонами

- Было проведено обучение отдельно на данных разных сезонов
- **Гиперпараметры:** функция потерь — бинарная кросс-энтропия, метрика для оценки точности — коэффициент Дайса, количество эпох — 260
- Лучший результат дает модель, обученная на данных всех сезонов

Обучение/тест	Имена тайлов Sentinel-2			
	T39VVJ	740VEM	T39VXH	T39VVJ+T39VXH +740VEM
все сезоны	0.611	0.663	0.674	0.654
переходный сезон (830 тайлов)	0.589	0.578	0.634	0.603
летний сезон (274 тайлов)	0.283	0.282	0.610	0.409
зимний сезон (872 тайлов)	0.471	0.565	0.351	0.428

U-net – бинарная классификация для разных типов вырубок

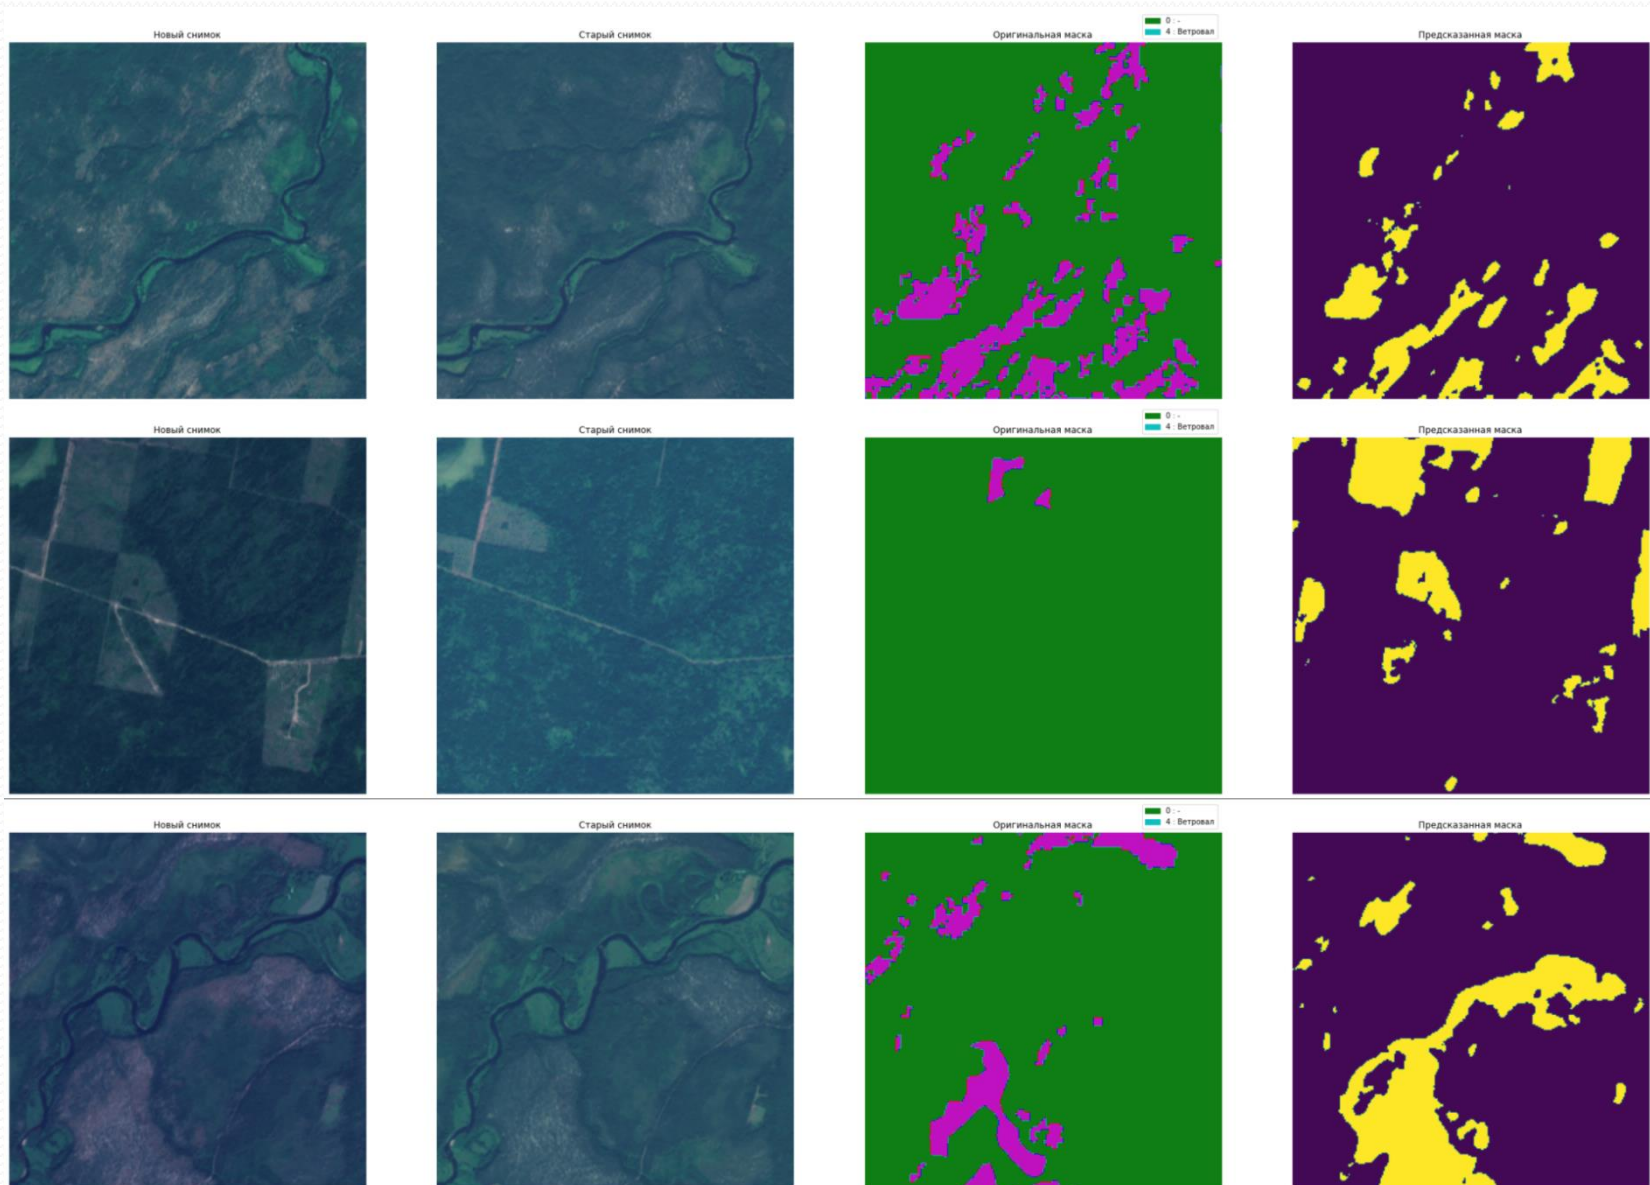


Идентификация ветровалов с помощью U-net

- Объем данных для тестирования – 370 образцов
- Признаки – те же, что и для вырубков (каналы B4, B8, B11, B12 и их разности)
- Функция потерь – коэффициент Дайса
- Гиперпараметры: количество эпох = 230, $lr = 1e^{-3}$, batch = 8

Порог вероятности	0,1	0,2	0,3	0,4
Коэфф. Дайса	0.691	0.734	0.747	0.747
IoU	0.856	0.807	0.764	0.721
sensitivity	0.986	0.991	0.994	0.995
specificity	0.753	0.781	0.790	0.790
F-мера	0.691	0.734	0.747	0.747

Результаты сегментации ветровалов (сверху, снизу) и вырубок (в центре)



Заключение и перспективы

- Мультиклассовая сегментация с помощью U-net пока дает неудовлетворительные результаты, бинарная классификация – удовлетворительные результаты
- Алгоритм U-net при любой функции потерь обеспечивает значительный прирост точности (по коэффициенту Дайса) в сравнении с XGBoost и Random Forest
- В свою очередь, для XGBoost и Random Forest некоторый прирост точности обеспечивается морфологическими преобразованиями результата
- Точность распознавания ветровалов с помощью U-net близка к аналогичному показателю для вырубок
- Перспективы исследования –
- Проверка разработанных моделей машинного обучения для новых данных
- Оценка точности для разных видов повреждений лесного покрова а и в разные сезоны
- Решение проблемы мультиклассовой сегментации нарушений лесного покрова
- Оценка влияния внешних факторов (породный состав и возраст насаждений, угол наклона склона – для горной местности, сезонный фактор)

An aerial photograph of a dense green forest. In the foreground, several tall, thin trees with long, thin branches are visible, their leaves appearing lighter green and more sparse than the surrounding forest. The main body of the forest is a thick, dark green canopy. The text "Спасибо за внимание" is overlaid in the center of the image.

Спасибо за внимание

*Андрей Шихов,
Пермский государственный университет
e-mail: and3131@inbox.ru
URL: <http://accident.perm.ru/>*