



NEURAL NETWORK-BASED DETERMINATION OF COARSE-GRAINED MATERIAL SIZE IN DEBRIS-FLOW DEPOSITS OF THE SOUTHERN BAIKAL REGION

A.A. Yuriev ^{1,2}✉, A.A. Rybchenko ^{1,2}, N.V. Kichigina ^{1,2}

¹ Institute of the Earth's Crust, Siberian Branch of the Russian Academy of Sciences, 128 Lermontov St, Irkutsk 664033, Russia

² Sochava Institute of Geography, Siberian Branch of the Russian Academy of Sciences, 1 Ulan-Batorskaya St, Irkutsk 664033, Russia

ABSTRACT. This study is devoted to automation of the assessment of the dimensional structure of coarse-grained material on orthophotomaps obtained from unmanned aerial vehicles (UAVs). Orthomosaics with a Ground Sample Distance (GSD) of ~2–4 cm were used on the material of ten debris-flow deposits of the Baikal region; an annotated dataset was prepared in SedimentAlyzer. The algorithm combines object detection by computer vision methods with subsequent classification and Feret diameter estimation using convolutional neural networks (CNN; architectures: residual convolutional network (ResNet) and densely connected convolutional network (DenseNet), transfer learning). The output is performed on overlapping cells; preliminary determinations are merged (non-maximum suppression, NMS / weighted boxes fusion, WBF), probabilities are calibrated (temperature scaling) and shape filters are applied. The implementation is integrated into SedimentAlyzer. The software is registered (state registration certificate for computer program No. 2025616929). The following values were achieved in the retained areas: F1-score = 0.84 ± 0.03 ; mean absolute Feret error = 4.8 cm; RMSE=7.9 cm; correlation with field measurements $R=0.89$; agreement with GOST size classes averaged 82 % across basins. Compared to manual interpretation, labor time is reduced by a factor of 6–8. Typical patterns include dominance of clasts 10–100 cm (≈ 30 –40 %) and a variable share of boulders >200 cm (1–13 % with maxima in small tributaries); in transit zones, the proportion of very large fragments is higher than in accumulation zones. The approach enables reproducible mapping of fractions and is suitable for regular monitoring of debris-flow cones and support of engineering decisions.

KEYWORDS: convolutional neural networks; debris-flow deposits; unmanned aerial vehicles; computer vision; Feret diameter; SedimentAlyzer; transfer learning

FUNDING: The study was supported by the RSF (project No. 24-27-20059).



EDN: YABBVX

RESEARCH ARTICLE

Correspondence: Anton A. Yuriev, antonyrevgeo@mail.ru

Received: March 17, 2025

Revised: August 26, 2025

Accepted: September 12, 2025

FOR CITATION: Yuriev A.A., Rybchenko A.A., Kichigina N.V., 2025. Neural Network-Based Determination of Coarse-Grained Material Size in Debris-Flow Deposits of the Southern Baikal Region. *Geodynamics & Tectonophysics* 16 (5), 0856. doi:10.5800/GT-2025-16-5-0856

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ РАЗМЕРА КРУПНООБЛОМОЧНОГО МАТЕРИАЛА В СЕЛЕВЫХ ОТЛОЖЕНИЯХ ЮЖНОГО ПРИБАЙКАЛЯ

А.А. Юрьев^{1,2}, А.А. Рыбченко^{1,2}, Н.В. Кичигина^{1,2}

¹ Институт земной коры СО РАН, 664033, Иркутск, ул. Лермонтова, 128, Россия

² Институт географии им. В.Б. Сочавы СО РАН, 664033, Иркутск, ул. Улан-Баторская, 1, Россия

АННОТАЦИЯ. Работа посвящена автоматизации оценки размерной структуры крупнообломочного материала на ортофотопланах, полученных с беспилотных летательных аппаратов. На материале десяти селевых бассейнов Прибайкалья использованы ортомозаики с наземным пространственным разрешением (GSD) ~2–4 см; аннотированная выборка подготовлена в SedimentAlyzer. Алгоритм объединяет определение объектов методами компьютерного зрения и последующую классификацию и оценку диаметра Ферре сверточными нейронными сетями (CNN; архитектура: остаточная сверточная сеть (ResNet) и плотносвязанная сверточная сеть (DenseNet), перенос обучения). Вывод выполняется по перекрывающимся ячейкам; предопределения объединяются (NMS/WBF), вероятности калибруются, применяются фильтры по форме. Реализация интегрирована в SedimentAlyzer. Программа зарегистрирована (свидетельство о государственной регистрации программы для ЭВМ № 2025616929). На удержанных участках достигнута F1-мера = 0.84 ± 0.03 ; средняя абсолютная ошибка по Ферре = 4.8 см; RMSE=7.9 см; корреляция с полевыми измерениями $R=0.89$; совпадение размерных классов по ГОСТ – 82 % в среднем по бассейнам. В сравнении с ручным дешифрированием трудозатраты сокращаются в 6–8 раз. Типичные закономерности включают доминирование гальки 10–100 мм (~30–40 %) и переменную долю валунов >200 мм (1–13 % с максимумами в малых притоках); в транзитных зонах доля очень крупных обломков выше, чем в аккумуляционных. Подход обеспечивает воспроизводимое картирование фракций и пригоден для регулярного мониторинга селевых конусов и поддержки инженерных решений.

КЛЮЧЕВЫЕ СЛОВА: сверточные нейронные сети; селевые отложения; беспилотные летательные аппараты; компьютерное зрение; диаметр Ферре; SedimentAlyzer; обучение с переносом

ФИНАНСИРОВАНИЕ: Исследование проведено при поддержке РНФ (проект № 24-27-20059).

1. ВВЕДЕНИЕ

Селевые потоки – один из наиболее опасных экзогенных процессов в горных районах Южного Прибайкалья. Их активизация приводит к разрушению объектов социальной и экономической инфраструктуры и трансформации русловых форм. Для регионов с регулярной активизацией селевых процессов объективная и оперативная оценка гранулометрического состава селевых отложений позволяет оценивать динамические характеристики селевых потоков [Agafonov, Rogozin, 1987; Stepanov, Stepanova, 1991; Oliferov, 2004; Fedorov et al., 2012; Laperdin et al., 2014; Kadetova et al., 2016; Aref'eva et al., 2017; Strom, 2022].

Традиционные подходы к определению гранулометрического состава (полевые замеры и визуальные оценки) весьма трудоемки и зависят от субъективного фактора, что ограничивает их применение [Rybchenko et al., 2019; Mamedov, 2013; Oliferov, 2004; Nosov, 2010].

Развитие методов дистанционного зондирования и искусственного интеллекта открывает возможности автоматизации для обработки и анализа данных. Аэрофотосъемка беспилотными летательными аппаратами (БПЛА) позволяет получать изображения высокой детальности, а методы компьютерного зрения и нейросетевые модели – эффективно анализировать полученные материалы [Stupin et al., 2020; Kedich et al.,

2022; Kharchenko et al., 2021; Velikanova, 2014; Mikhailov et al., 2016; Puritskis, Vershinin, 2023; Bezgodova et al., 2018; Ivanko et al., 2019; Loginov, Petrov, 2019].

Цель исследования – разработать и апробировать метод автоматического определения размеров крупнообломочного материала на примере селевых отложений Южного Прибайкалья по данным БПЛА с применением методов компьютерного зрения и нейросетей. Задачи: (1) подготовить и описать единый алгоритм подготовки данных и измерения; (2) выполнить автоматизированную оценку размеров и классификацию фракций; (3) получить и интерпретировать пространственные распределения по бассейнам и морфодинамическим зонам; (4) сравнить результаты с традиционными методами определения гранулометрического состава.

Объекты исследования, перечисленные в табл. 1, представляют собой комплекс селевых отложений, расположенных в руслах селеактивных рек и ручьев на территории Южного Прибайкалья [Agafonov, Makarov, 1996; Laperdin, Rybchenko, 2016; Makarov, 2012].

По данным [Agafonov, Makarov, 1996; Makarov, 2012] активизация селевого процесса в Южном Прибайкалье зафиксирована в 1863, 1890, 1903, 1905, 1910, 1915, 1919, 1925, 1927, 1932, 1934, 1935, 1938, 1940, 1942, 1945, 1947, 1952, 1956, 1959, 1960, 1962, 1965, 1971, 1973 годах. Последние опасные проявления селевого процесса

зафиксированы в селеактивных бассейнах хребта Тункинские Гольцы в 2014 г., а в селеактивных бассейнах хребта Хамар-Дабан в 2019 и 2023 гг.

Внедрение нейросетевых технологий в изучение селевого процесса открывает новые возможности и перспективы для оценки и анализа этапов его развития. В данной статье представлены результаты исследования, обсуждение методологии и выводы, которые могут стать основой для дальнейших разработок в этой области.

2. МАТЕРИАЛЫ И МЕТОДЫ

В настоящем исследовании авторы использовали комплексный подход к сбору и обработке данных, что позволило создать высококачественную базу для разработки и тестирования нейросетевой модели. Основ-

Таблица 1. Перечень ключевых участков исследования
Table 1. List of key study areas

Южное Прибайкалье	
Тункинские Гольцы (район п. Аршан)	Южное побережье оз. Байкал
р. Кынгырга	р. Слюдянка
р. Первая Шихтолайка	р. Бабха
р. Вторая Шихтолайка	р. Харлахта
руч. Первый Безымянный	р. Солзан
руч. Второй Безымянный	р. Бол. Осиновка
руч. Красный	–

Таблица 2. Характеристики БПЛА
Table 2. Specification of UAVs

Модель БПЛА	Сенсор	Эффективное разрешение	GSD при 100 м	Позиционирование
Autel Robotics EVO Lite+	CMOS, 1»	50 Мп	8.28 см/пкс	GPS
DJI Phantom 4 RTK	CMOS, 1»	20 Мп	10.00 см/пкс	RTK




Рис. 1. Используемые БПЛА: Autel Robotics lite+ (а), DJI Phantom 4 RTK (б).
Fig. 1. UAVs used: Autel Robotics Lite+ (a), DJI Phantom 4 RTK (b).

ными результатами исследования стали: разработанное программное обеспечение и итоги его применения для обработки и анализа данных аэрофотосъемки полученных с помощью БПЛА.

2.1. Техническое оснащение и выбор оборудования

Для проведения аэрофотосъемки были выбраны передовые модели БПЛА, такие как Autel Robotics EVO Lite+ и DJI Phantom 4 RTK (табл. 2; рис. 1). Эти устройства оснащены камерами с CMOS-матрицами, позволяющими получать изображения с разрешением до 50 Мп. Благодаря интеграции систем глобального позиционирования, включая технологию кинематического позиционирования в реальном времени (RTK), удалось достичь максимальной точности в определении географических координат привязки местоположения БПЛА, что является основой для создания высокоточных ортофотопланов и трехмерных моделей исследуемой местности.

2.2. Методика аэрофотосъемки

Аэрофотосъемка осуществлялась на высоте от 20 до 100 м, что позволило получить оптимальное разрешение снимков, необходимое для анализа крупнообломочного материала. Масштаб аэрофотосъемки тщательно рассчитывался с учетом высоты полета и фокусного расстояния камеры, обеспечивая необходимую детализацию для последующего анализа. В процессе съемки учитывались погодные условия и топографические особенности местности, что гарантировало получение качественных и достоверных данных, пригодных для всестороннего анализа.

Из-за технических особенностей БПЛА (погодные условия, время автономной работы, топография местности, качество связи, энергопотребление) удалось проанализировать данные по селевым бассейнам с различной степенью детальности. В табл. 3 демонстрируется процентное соотношение объема проанализированной информации для каждого из бассейнов в районе Тункинских Гольцов и на Южном побережье оз. Байкал. Эти данные позволяют оценить объем проведенных исследований и выявить области, требующие дальнейшего изучения.

Расчет пространственного разрешения аэрофото-съемки является важным шагом для определения качества и детализации получаемых изображений. Наземное пространственное разрешение (GSD) определяет размер пикселя на местности и напрямую зависит от высоты полета и фокусного расстояния камеры. Ниже представлена стандартная формула для расчета пространственного разрешения аэрофотосъемки:

$$GSD = \frac{H \cdot PS}{F},$$

где GSD – разрешение в метрах на пиксель; H – высота полета в метрах; PS – размер пикселя в микрометрах; F – фокусное расстояние камеры (в тех же единицах измерения).

Формула GSD определяет, какому реальному размеру на земле соответствует один пиксель снимка, что важно для оценки детализации и точности аэрофотосъемки.

2.3. Преимущества и достоинства использования БПЛА

Применение БПЛА обеспечивает получение изображений с высоким пространственным разрешением, быстрый и безопасный доступ к труднодоступным и потенциально опасным участкам, а также оперативное обновление данных о состоянии исследуемой территории. Эти возможности позволяют детально картировать распределение обломочного материала в селевых отложениях и существенно сокращают временные и снижают трудовые затраты в 6–8 раз по сравнению с традиционными методами.

2.4. Изображения и ортофотопланы

На основе данных, полученных с помощью БПЛА, были созданы ортофотопланы исследуемых участков. Эти материалы служат основой для обучения нейросетевой модели. Высокое качество изображений обеспечивает возможность точного определения размеров и распределения крупнообломочного материала в селевых отложениях.

2.5. Подход к обработке данных с использованием библиотеки компьютерного зрения (OpenCV)

Обработка изображений выполнялась в программной среде SedimentAlyzer с использованием библиотеки OpenCV. Последовательность этапов включала:

Таблица 3. Объем данных проанализированных селевых бассейнов

Table 3. Data volume for analyzed debris-flow basins

Селевой бассейн	Проанализированный объем, %
Тункинские Гольцы (район п. Аршан)	
р. Кынгырга	40.71
р. Первая Шихтолайка	71.17
р. Вторая Шихтолайка	91.96
руч. Первый Безымянный	92.85
руч. Второй Безымянный	76.45
руч. Красный	75.65
Южное побережье оз. Байкал	
р. Слюдянка	19.20
р. Бабха	22.56
р. Харлахта	82.33
р. Солзан	18.49
р. Бол. Осиновка	46.47

1) конвертацию изображений в 8-битный формат и, при необходимости, линейную нормализацию гистограммы для выравнивания яркостных уровней;

2) сглаживание с помощью гауссова фильтра (размер ядра подбирался в диапазоне 3×3 – 7×7 пикселей в зависимости от GSD и ожидаемого размера контуров) для снижения шума;

3) детекцию контуров методом Канны с пороговыми значениями, рассчитанными автоматически на основе медианы градиента изображения;

4) морфологические операции для замыкания контуров и удаления мелких шумов (рис. 2);

5) векторизацию контуров и извлечение метрических признаков (максимальное сечение / Ферре, площадь, периметр, компактность и др.);

6) проверку оцифровки объектов вручную в программе SedimentAlyzer с контролем корректности обрисовки.

Такой алгоритм позволил унифицировать обработку данных, повысить точность выделения объектов и обеспечить воспроизводимость анализа при последующем обучении нейросетевых моделей.

2.6. Интеграция нейросетей в анализ обломочного материала

Постановка задачи и допущения. В исследовании решается задача одновременной детекции и размерной классификации отдельных обломков на ортофотопланах, полученных с БПЛА.

В качестве исходных данных используются ортоизображения с известным GSD. Классы соответствуют размерным категориям по [ГОСТ..., 2020] (табл. 4).

Модель для каждой выделенной области на изображении оценивает вероятность принадлежности к тому или иному классу и определяет максимальное




Рис. 2. Результаты постобработки ортофотоплана.
Fig. 2. Results of orthophotomap post-processing.

сечение обломка. Значения переводятся в сантиметры с учетом GSD.

Предполагается, что обломки расположены в одной плоскости с поверхностью ортофото, а частичные перекрытия могут быть корректно устранены на этапе постобработки.

Общая архитектура. Реализован алгоритм, включающий выделение объектов методами компьютерного зрения (детекция контуров по Канни, морфологические операции, векторизация), что позволяет снизить количество ложных срабатываний; классификацию и оценку размеров с помощью CNN архитектур остаточной сверточной сети (ResNet) [He et al., 2016] и плотносвязанной сверточной сети (DenseNet) [Huang et al., 2016], дообученных в режиме переноса обучения на базе предобученных весов ImageNet [Deng et al., 2009]. ResNet обеспечивает устойчивое обучение за счет остаточных связей, а DenseNet – эффективное использование признаков благодаря плотным соединениям [Yosinski et al., 2014].

Нормализация масштаба и подготовка входных данных. Для сопоставимости результатов между участками с разным разрешением применяется масштабная нормализация: все изображения приводятся к единому масштабу.

Входные данные дополнительно проходят нормировку и при необходимости ограничение по контрасту адаптивного выравнивания гистограммы. Используются аугментации – случайные повороты, масштаби-

Таблица 4. Классификация крупнообломочных грунтов по гранулометрическому составу
Table 4. Classification of coarse-clast soils by granulometric composition

Элементы грунта	Фракции	Размер фракций, мм
Валуны (глыбы)	Крупные	>800
	Средние	800–400
	Мелкие	400–200
Галька (щебень)	Крупные	200–100
	Средние	100–60
	Мелкие	60–10
Гравий (дресва)	Крупные	10–5
	Мелкий	5–2

рование, изменение яркости и контраста, небольшие сдвиги, что повышает устойчивость модели к теням, бликам и различным условиям съемки.

Аннотация и контроль качества. Разметка выполнялась в программе SedimentAlyzer с использованием встроенного инструмента программы labelme. Для каждого объекта создавался полигон с указанием размерного класса по [GOST..., 2020] и измеренным максимальным сечением (рис. 3).

Контроль качества включал внутреннюю валидацию (повторная разметка части данных для оценки

согласия между разметчиками) и проверку геометрической точности по калибровочным меткам и расчетному GSD.

Функции потерь и работа с дисбалансом классов. Обучение проводилось с использованием комбинированной функции потерь: взвешенная кросс-энтропия для классификации и Smooth L1 Loss для оценки размеров [Girshick, 2015].

При дисбалансе классов применялась фокальная функция потерь, которая увеличивает вклад редких классов в обучение [Lin et al., 2017].

Гиперпараметры и процедура обучения. Модели обучались на графическом процессоре RTX 4060 (8 ГБ).

Основные параметры: размер батча 32, оптимизатор Adam [Kingma, Ba, 2015], скорость обучения с постепенным уменьшением, 50–100 эпох с ранней остановкой по валидационным метрикам. Применялись Batch Normalization [Ioffe, Szegedy, 2015] и Dropout [Srivastava et al., 2014].

Данные делились на обучающую и тестовую выборки по пространственным участкам для исключения утечки информации.

Инференс и постобработка. Применялся метод разбиения ортофотоплана на перекрывающиеся фрагменты. Полученные предсказания объединялись с помощью алгоритмов подавления дубликатов.

В постобработке использовались фильтры по форме и площади, а также разбиение слипшихся объектов (рис. 4). По итогам строились карты распределения классов и карты плотности (рис. 5).

Калибровка, неопределенность и оценка качества. Для улучшения интерпретируемости прогнозов выполнялась калибровка вероятностей [Guo et al., 2017].

Неопределенность оценивалась методами аугментации на этапе инференса (TTA) и стохастическим dropout на инференсе MC-Dropout [Gal, Ghahramani, 2016].

Уровень качества определялся по средним абсолютным ошибкам, корню из среднеквадратичной ошибки (MAE, RMSE), коэффициенту корреляции, а также по метрикам точности, полноты и F1-меры. Пороговые значения подбирались по ROC/PR-кривым [Fawcett, 2006; Davis, Goadrich, 2006].

Валидация. Протокол сопоставления с полевыми измерениями. Для независимой проверки точности авторы провели полевой аудит на реперных площадках во всех бассейнах. Структура и процедура выборки были следующими.

Структура выборки. В каждом бассейне отобрано по 3–4 реперные площадки (итого 32 площадки, размер 10×10 м), стратифицированные по морфодинамическим зонам (транзит/аккумуляция). На каждой площадке инструментально измерено 30–50 обломков (всего ≈1160 объектов).

Полевые измерения. Для каждого обломка фиксировались: Ферре (лента/рейка с ценой деления 1 см), при необходимости – второй перпендикулярный размер; фотография с масштабной рейкой; краткое описание покрытия/тени. Координаты углов площадки и нескольких контрольных точек снимались RTK (горизонтальная точность ±2–3 см).




Рис. 3. Этап процесса определения объектов инструментом labelme, интегрированным в программу SedimentAlyzer.

Fig. 3. Stage of the object determination process using the labelme tool integrated into SedimentAlyzer.




Рис. 4. Этап предопределения граней крупнообломочного материала.

Fig. 4. Stage of coarse-grained material facet preliminary determination.




Рис. 5. Карта плотности крупнообломочного материала.

Fig. 5. Coarse-grained material density map.

Совмещение с ортофотопланом. Ортомозаики проходили контроль внутренней согласованности и при необходимости локальную подгонку по RTK-точкам, чтобы систематическая ошибка позиционирования не превышала 1 GSD. Для каждой площадки формировалась область интереса (ROI).

Совмещение объектов. Предопределенные полигоны сопоставлялись с полевыми обломками по «пересечению над объединением» (IoU) ≥ 0.5 (при возникновении конкуренции выбиралась пара с максимальным IoU). Несопоставленные предсказания учитывались как FP, несопоставленные полевые объекты – как FN. Размер на ортофото переводился в сантиметры через GSD.

Контроль воспроизводимости. 10 % объектов перемерялись вторым оператором: межоператорная погрешность составила ± 2.5 см MAE, что задает нижнюю границу ожидаемой ошибки «на земле».

Статистика и неопределенность. Оценки точности получены в разрезе бассейнов и зон, доверительные интервалы рассчитаны бутстрэпом (1000 перестановок, стратификация по площадкам).

2.7. Метрики и полученные ошибки

Обнаружение/классификация: точность (precision) = 0.87, полнота (recall) = 0.82, F1-мера = 0.84 ± 0.03 . Совпадение размерных классов по ГОСТ на уровне объекта – 82 % (среднее по бассейнам). Оценка размера (Ферре): MAE=4.8 см, метрика оценки точности (RMSE) = 7.9 см, медианная абсолютная ошибка 3.9 см, 90-й перцентиль 12.5 см. Среднее смещение (bias) +0.6 см (незначительное перевыделение на контрастных тенях). Корреляция с полем $R=0.89$; регрессия «прогноз vs поле»: наклон 0.96 ± 0.03 , свободный член +0.9 см.

По зонам: в транзитных участках MAE=5.6 см, в аккумуляционных – 4.2 см (хуже в транзите из-за перекрытий и теней). По классам: наименьшая ошибка для гальки 10–100 см (MAE $\approx$ 3.7 см), наибольшая – для валунов >200 см (MAE $\approx$ 7.1 см), что отражает рост дисперсии с размером. Влияние GSD: при GSD 2–3 см точность максимальна; при 4 см MAE возрастает на ≈ 0.6 –0.8 см.

Источники ошибок и их контроль. Ключевые факторы: тени/спекулярные блики (локальное завышение размера), высокая плотность мелких фракций («слипание» контуров), частичная засыпанность обломков. Для их компенсации применялись: калибровка вероятностей, фильтры формы (компактность, эксцентриситет), разбиение кластеров по расстояниям до гребней, а также целевая доразметка «трудных» сцен.

Суммарно полученная точность (MAE порядка 5 см при $R \approx 0.89$ и согласии классов ≈ 82 %) достаточна для задач инженерного анализа и регулярного мониторинга, а воспроизводимость конвейера обеспечивает переносимость методики на новые участки съемки без полной перенастройки.

3. РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Исследование, направленное на автоматизацию определения размеров крупнообломочного материала

ла в селевых отложениях, позволило получить ряд результатов, которые определяют эффективность разработанной методики и ее практическую ценность. В этом разделе представлены основные результаты анализа, включая оценку крупности обломочного материала в исследуемых селевых бассейнах.

3.1. Визуализация результатов анализа

График плотности стал одним из ключевых инструментов для анализа распределения размеров объектов в исследуемой области. Он был построен на основе максимальных расстояний между точками в пределах каждого полигона, что позволяет визуализировать распределение размеров объектов. График помогает выявить наиболее распространенные размеры обломков (рис. 6).

Гистограмма максимальных сечений является важным инструментом для анализа вариативности размеров обломков на исследуемом участке. На основе данных о максимальных расстояниях между точками в пределах каждого полигона гистограмма позволяет получить представление о распределении размеров обломков и их частоте (рис. 7).

Визуализация результатов позволяет не только оценить текущее распределение фракций гранулометрического состава на исследуемом участке, но и выявить потенциальные области для более детального изучения. В будущем улучшение алгоритмов классификации и точности обработки изображений может привести к более точному анализу.

3.2. Процентное распределение крупнообломочного материала

В табл. 5 приведены доли размерных фракций в пределах каждого бассейна (средние по всей изученной площади бассейна). В большинстве бассейнов преобладает галька 10–100 мм (30–40 %). Доля валунов >200 мм обычно ≤ 10 %, но достигает 13 % во втором Безымянном ручье. Бассейны с заметной долей мелких обломков (например, Красный, Первый и Второй Безымянный ручьи) связаны с локальными источниками рыхлого материала и/или особенностями гидродинамики потока. Эти закономерности подтверждают важность учета размерной структуры при оценке морфодинамического состояния селевых отложений.

Для уточнения влияния морфодинамических условий на гранулометрический состав селевых отложений был выполнен анализ распределения фракций в пределах двух основных морфодинамических зон – транзитной и аккумуляционной. В табл. 6 представлены средние значения долей мелких, средних, крупных и очень крупных обломков по каждой зоне, усредненные по всем исследованным бассейнам.

Как видно из табл. 6, зоны транзита участков характеризуются повышенной долей очень крупных обломков (валуны) и крупной фракции 100–200 мм, тогда как в аккумуляционных зонах существенно возрастает доля мелких фракций. В среднем по бассейнам




Рис. 6. График плотности распределения размеров крупнообломочного материала.

Fig. 6. Density plot of coarse-clast size distribution.




Рис. 7. Гистограмма максимальных сечений крупнообломочного материала.

Fig. 7. Histogram of maximum cross-sections of coarse-clast.

Таблица 5. Распределение крупнообломочного материала по селевым бассейнам

Table 5. Distribution of coarse-clast across debris-flow basins

Объект исследования	Мелкие обломки (гравий до 10 см), %	Средние обломки (галька 10–100 см), %	Крупные обломки (100–200 см), %	Очень крупные обломки (валуны более 200 см), %
р. Кынгырга	15	35	30	2
р. Слюдянка	10	40	30	1
р. Первая Шихтолайка	20	30	25	8
р. Вторая Шихтолайка	22	33	28	6
р. Бабха	12	38	30	4
р. Харлахта	18	32	28	3
р. Солзан	14	36	29	6
руч. Первый Безымянный	22	28	25	10
руч. Второй Безымянный	25	30	28	13
руч. Красный	27	34	31	9

Таблица 6. Распределение крупнообломочного материала по морфодинамическим зонам селевого бассейна
Table 6. Distribution of coarse-clast by morphodynamic zones of the debris-flow basin

Морфодинамические зоны селевого бассейна	Гравий (дресва) (до 10 мм), %	Галька (щебень) (мелкие, средние – 10–100 мм), %	Галька (щебень) (крупные – 100–200 мм), %	Валуны (глыбы), (более 200 мм), %
Зоны зарождения	Данные отсутствуют			
	р. Кынгырга			
	14.23	39.12	27.54	19.11
	р. Слюдянка			
	16.54	34.87	30.21	18.38
	р. Первая Шихтолайка			
	20	30	25	8
	р. Вторая Шихтолайка			
	21.76	28.13	25.88	24.23
	р. Бабха			
Зоны транзита	19.65	32.77	28.69	18.89
	р. Харлахта			
	18.79	32.58	26.84	21.79
	р. Солзан			
	15.72	35.64	31.88	16.76
	руч. Первый Безымянный			
	20.91	26.78	25.92	26.39
	руч. Второй Безымянный			
	23.87	28.45	28.51	19.17
	руч. Красный			
	25.43	33.12	32.15	9.30
	р. Кынгырга			
	23.54	28.87	29.11	18.48
	р. Слюдянка			
	25.89	34.11	26.34	13.66
	р. Первая Шихтолайка			
	32.45	25.34	23.78	18.43
	р. Вторая Шихтолайка			
	28.23	31.45	24.56	15.76
	р. Бабха			
Зоны аккумуляции	29.87	35.66	26.54	7.93
	р. Харлахта			
	27.34	33.11	25.45	14.10
	р. Солзан			
	26.21	32.56	27.32	13.91
	руч. Первый Безымянный			
	31.45	23.67	21.89	22.99
	руч. Второй Безымянный			
	34.78	25.56	26.67	12.99
	руч. Красный			
	36.54	30.33	28.11	5.02

получено: в транзите – мелкие 19.7 ± 3.5 %, средние 32.1 ± 3.8 %, крупные 28.3 ± 2.5 %, валуны 18.2 ± 5.8 %; в аккумуляции – мелкие 29.6 ± 4.2 %, средние 30.1 ± 4.1 %, крупные 26.0 ± 2.1 %, валуны 14.3 ± 5.2 %. Различия статистически значимы для мелких ($p=0.002$) и крупных 100–200 мм ($p=0.014$) фракций; для валунов эффект пограничный ($p \approx 0.064$), что объясняется высокой межучастковой вариабельностью. Эти результаты согласуются с физикой процесса: в транзите сохраняются более «энергоёмкие» потоки с переносом крупного материала, тогда как в аккумуляции преобладают условия осаждения мелких/средних фракций.

3.3. Сравнение с традиционными методами

Сопоставление проводилось на 32 реперных площадках (каждая 10×10 м) с инструментальными измерениями ~ 160 обломков (см. методику в разделе 2.6: RTK привязка, совмещение по $IoU \geq 0.5$, пересчет размеров через GSD). Получено:

- классификация по [GOST..., 2020]: точность = 0.87, полнота = 0.82, F1-мера = 0.84 ± 0.03 ; доля совпадений с полевым классом – 82 % (среднее по бассейнам);

- размер (Ферре): MAE=4.8 см, RMSE=7.9 см, медианная ошибка 3.9 см, 90-й перцентиль 12.5 см; корреляция с полем $R=0.89$; смещение +0.6 см (незначительное завышение на контрастных тенях);

- по зонам: MAE в транзите 5.6 см, в аккумуляции 4.2 см (хуже в транзите из-за перекрытий и теней);

- по классам: минимальная ошибка для гальки 10–100 см (~ 3.7 см), максимальная – для валунов >200 см (~ 7.1 см).

Типовые расхождения и их причины. (I) Тени/блики → локальное «перевыделение» границ (положительный bias); (II) высокая плотность мелких фракций → «слипание» контуров; (III) частичная засыпанность обломков. Компенсация: калибровка вероятностей, фильтры формы (компактность, эксцентриситет), разбиение кластеров и целевая доразметка «трудных» сцен.

4. ЗАКЛЮЧЕНИЕ

Предложенный алгоритм автоматического анализа (выделение обломков методами компьютерного зрения и последующая классификация/оценка Ферре сверточными нейронными сетями ResNet/DenseNet с переносом обучения) показал на выбранных участках устойчивые данные точности: F1-мера= 0.84 ± 0.03 , MAE по диаметру Ферре=4.8 см, RMSE=7.9 см, корреляция с полевыми измерениями $R=0.89$, доля совпадений размерных классов по [GOST..., 2020] – 82 % при небольшом смещении +0.6 см (завышение на контрастных тенях). Типичное распределение фракций в бассейнах характеризуется доминированием гальки 10–100 см (~ 30 –40 %) и переменной долей валунов >200 мм (1–13 %; максимум отмечен во втором Безымянном ручье), что согласуется с графиком плотности и гистограммой размеров. Агрегированное сравнение морфодинамических зон подтверждает ожидаемую физику

процесса: в транзитных участках выше доли крупной фракции 100–200 мм и валунов (в среднем мелкие 19.7 ± 3.5 %, средние 32.1 ± 3.8 %, крупные 28.3 ± 2.5 %, валуны 18.2 ± 5.8 %), тогда как в аккумуляции растет доля мелких фракций (мелкие 29.6 ± 4.2 %, средние 30.1 ± 4.1 %, крупные 26.0 ± 2.1 %, валуны 14.3 ± 5.2 %); различия статистически значимы для мелких ($p=0.002$) и крупной, 100–200 мм ($p=0.014$), фракций, для валунов эффект пограничный ($p \approx 0.064$).

Производительность алгоритма обеспечивает сокращение трудозатрат на определение гранулометрического состава: обработка участка площадью 0.3–0.5 км² занимает 25–35 мин против 3–4 ч при ручном дешифрировании (ускорение в 6–8 раз) при сопоставимом качестве; минимальные ошибки достигаются при GSD 2–3 см, при ~ 4 см MAE возрастает на ~ 0.6 –0.8 см. Основные источники погрешностей – тени/блики, «слипание» контуров при высокой плотности мелких фракций и частичная засыпанность обломков – компенсируются калибровкой вероятностей, фильтрами формы (компактность, эксцентриситет), разбиением кластеров и учетом неопределенности TTA/MC-Dropout с целевой доразметкой «трудных» участков. Реализация в программе SedimentAlyzer (патент РФ № 2025615699) обеспечивает воспроизводимость и переносимость методики на новые бассейны, а суммарные метрики (MAE порядка 5 см, $R \approx 0.89$, согласие классов ~ 82 %) свидетельствуют о ее пригодности для регулярного мониторинга селевых конусов и обоснования инженерных решений по снижению риска.

5. ЗАЯВЛЕННЫЙ ВКЛАД АВТОРОВ / CONTRIBUTION OF THE AUTHORS

Все авторы внесли эквивалентный вклад в подготовку рукописи, прочли и одобрили финальную версию перед публикацией.

All authors made an equivalent contribution to this article, read and approved the final manuscript.

6. РАСКРЫТИЕ ИНФОРМАЦИИ / DISCLOSURE

Авторы заявляют об отсутствии конфликта интересов, связанного с этой рукописью.

The authors declare that they have no conflicts of interest relevant to this manuscript.

7. ЛИТЕРАТУРА / REFERENCES

Agafonov B.P., Makarov S.A., 1996. Debris Flow Areas in Pribaikalye. *Geoecology. Engineering Geology. Hydrogeology. Geocryology* 2, 65–71 (in Russian) [Агафонов Б.П., Макаров С.А. Ареалы селевых потоков в Прибайкалье // Геоэкология. Инженерная геология. Гидрогеология. Геокриология. 1996. № 2. С. 65–71].

Agafonov B.P., Rogozin A.A., 1985. Quantitative Assessment of Debris Flow Drift Into Lake Baikal. In: *Problems of Geology and Paleogeography of Siberia and the Far East*. ISU Publishing House, Irkutsk, p. 53–63 (in Russian) [Агафонов Б.П., Рогозин А.А. Количественная оценка селевого сноса в озеро Байкал // Вопросы геологии и

палеогеографии Сибири и Дальнего Востока. Иркутск: Изд-во ИГУ, 1985. С. 53–63].

Aref'eva E.V., Babusenko M.S., Baryshev E.M., Bobreshov D.A., Boreiko V.Ya., Vereskun A.V., Glebov V.Yu., Efimova A.A. et al., 2017. Protecting Populations and Territories in Emergencies Under Current Challenges and Threats: A Reference Manual. VNII GOCHS, Moscow, 452 p. (in Russian) [Арефьева Е.В., Бабусенко М.С., Барышев Е.М., Бобрешов Д.А., Бореико В.Я., Верескун А.В., Глебов В.Ю., Ефимова А.А. и др. Проблемы защиты населения и территорий в чрезвычайных ситуациях в условиях современных вызовов и угроз: Справочное пособие. М.: ВНИИ ГОЧС, 2017. 452 с.].

Bezgodova O.V., Istomina E.A., Ovchinnikova E.V., 2018. Assessment of Hazardous Exogenous Processes of the Mondy Depression Based on Morphometric and Landscape Analysis. *Geodesy and Cartography* 79 (8), 28–37 (in Russian) [Безгодова О.В., Истомина Е.А., Овчинникова Е.В. Оценка и картографирование опасных экзогенных процессов Мондинской котловины на основе морфометрического ландшафтного анализа // Геодезия и картография. 2018. Т. 79. № 8. С. 28–37]. <https://doi.org/10.22389/0016-7126-2018-938-8-28-37>.

Davis J., Goadrich M., 2006. The Relationship Between Precision-Recall and ROC Curves. In: W.W. Cohen, A. Moore (Eds), *ICML'06. Proceedings of the 23rd International Conference on Machine Learning* (June 25–29, 2006, Pittsburgh, Pennsylvania, USA). Association for Computing Machinery, New York, p. 233–240. <https://doi.org/10.1145/1143844.1143874>.

Deng J., Dong W., Socher R., Li L.J., Li K., Fei-Fei L., 2009. ImageNet: A Large-Scale Hierarchical Image Database. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (June 20–25, 2009, Miami, FL, USA). IEEE, p. 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>.

Fawcett T., 2006. An Introduction to ROC Analysis. *Pattern Recognition Letters* 27 (8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>.

Fedorov Yu.A., Kyul E.V., Dzhabpuev D.R., 2012. Features of Debris Flow Formation Under Complex Geological and Hydrological Conditions. *Bulletin of Higher Education Institutes. North Caucasus Region. Natural Sciences* 2 (168), 101–104 (in Russian) [Федоров Ю.А., Кюль Е.В., Джаппуев Д.Р. Особенности селеформирования в сложных геолого-гидрологических условиях // Известия вузов. Северо-Кавказский регион. Естественные науки. 2012. № 2 (168). С. 101–104].

Gal Y., Ghahramani Z., 2016. Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. In: M.F. Balcan, K.Q. Weinberger (Eds), *ICML'16. Proceedings of the 33rd International Conference on Machine Learning* (June 20–22, 2016, New York, USA). Vol. 48. *JMRL*, p. 1050–1059.

Girshick R., 2015. Fast R-CNN. In: *Proceedings of the IEEE Conference on Computer Vision* (December 7–13, 2015, Santiago, Chile). IEEE, p. 1440–1448. <https://doi.org/10.1109/ICCV.2015.169>.

GOST 25100-2020, 2020. Grounds. Classification. Standardinform, Moscow, 38 p. (in Russian) [ГОСТ 25100-2020. Грунты. Классификация. М.: Стандартинформ, 2020. 38 с.].

Guo C., Pleiss G., Sun, Y., Weinberger K.Q., 2017. On Calibration of Modern Neural Networks. In: D. Precup, Ye.W. Teh (Eds), *ICML'17. Proceedings of the 34th International Conference on Machine Learning* (August 6–11, 2017, Sydney, Australia). Vol. 70. *JMRL*, p. 1321–1330.

He K., Zhang X., Ren S., Sun J., 2016. Deep Residual Learning for Image Recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (June 27–30, 2016, Las Vegas, Nevada, USA). IEEE, p. 770–778. <https://doi.org/10.1109/CVPR.2016.90>.

Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q., 2016. Densely Connected Convolutional Networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (July 21–26, 2017, Honolulu, HI, USA). IEEE, p. 4700–4708. <https://doi.org/10.1109/CVPR.2017.243>.

Ioffe S., Szegedy C., 2015. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In: F. Bach, D. Blei (Eds), *ICML'15. Proceedings of the 32nd International Conference on Machine Learning* (July 7–9, 2015, Lille, France). Vol. 37. *JMRL*, p. 448–456.

Ivanko A.F., Ivanko M.A., Sizova Yu.A., 2019. Neural Networks: General Technological Characteristics. *Scientific Review. Technical Sciences* 2, 17–23 (in Russian) [Иванько А.Ф., Иванько М.А., Сизова Ю.А. Нейронные сети: общие технологические характеристики // Научное обозрение. Технические науки. 2019. № 2. С. 17–23].

Kadetova A.V., Rybchenko A.A., Kozyreva E.A., Tie Y., Ni H., 2016. Debris Flow Event of 2014 and Its Impact on the Accumulation of the Solid Fraction in the Kyngarga River Channel, Tunka Valley, Southwestern Cisbaikalia, Russia. *Geodynamics & Tectonophysics* 7 (2), 329–335. <https://doi.org/10.5800/GT-2016-7-2-0210>.

Kedich A.I., Golosov V.N., Kharchenko S.V., 2022. Exogenous Processes in Proglacial Mountain Zones: Quantitative Assessments and Their Accuracy. *Proceedings of Kazan University. Natural Sciences Series* 164 (1), 109–134 (in Russian) [Кедич А.И., Голосов В.Н., Харченко С.В. Экзогенные процессы в прогляциальных зонах гор: количественные оценки и их точность // Ученые записки Казанского университета. Серия Естественные науки. 2022. Т. 164. № 1. С. 109–134]. <https://doi.org/10.26907/2542-064X.2022.1.109-134>.

Kharchenko S.V., Fedin A.V., Golosov V.N., 2021. Denudation Rates in the Mountain Periglacial Regions: Research Methods and Results. *Geomorphology and Paleogeography* 52 (1), 3–18 (in Russian) [Харченко С.В., Федин А.В., Голосов В.Н. Темпы денудации в перигляциальных областях высокогорий: методы и результаты исследований // Геоморфология и палеогеография. 2021. Т. 52. № 1. С. 3–18]. <https://doi.org/10.31857/S0435428121010065>.

Kingma D.P., Ba J., 2015. Adam: A Method for Stochastic Optimization. In: *Proceedings of the 3rd International*

Conference on Learning Representations (May 7–9, 2015, San Diego). <https://doi.org/10.48550/arXiv.1412.6980>.

Laperdin V.K., Levi K.G., Lekhatinov A.M., Kadetova A.V., Pellinen V.A., Rybchenko A.A., 2014. Causes and Consequences of a Catastrophic Mudflows on 28 June 2014 near Arshan Village in the Republic of Buryatia, Russia. *Geodynamics & Tectonophysics* 5 (3), 799–816 (in Russian) [Лапердин В.К., Леви К.Г., Лехатинов А.М., Кадетова А.В., Пеллинен В.А., Рыбченко А.А. Причины и последствия катастрофических селевых потоков 28 июня 2014 г. в окрестностях пос. Аршан, Республика Бурятия // Геодинамика и тектонофизика. 2014. Т. 5. № 3. С. 799–816]. <https://doi.org/10.5800/GT-2014-5-3-0156>.

Laperdin V.K., Rybchenko A.A., 2016. Estimated Parameters of Mudflow Forming Components of the Environment of the South of Lake Baikal. *Sustainable Development of Mountain Territories* 8 (1), 52–58 (in Russian) [Лапердин В.К., Рыбченко А.А. Оценочные параметры селеформирующих компонентов природной среды юга озера Байкал // Устойчивое развитие горных территорий. 2016. Т. 8. № 1. С. 52–58]. <https://doi.org/10.21177/1998-4502-2016-8-1-52-57>.

Lin T.Y., Goyal P., Girshick R., He K., Dollár P., 2017. Focal Loss for Dense Object Detection. In: *Proceedings of the IEEE International Conference on Computer Vision* (October 22–29, 2017, Venice, Italy). IEEE, p. 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>.

Loginov G.N., Petrov A.M., 2019. Automatic Detection of Geoelectric Boundaries According to Lateral Logging Sounding Data by Applying a Deep Convolutional Neural Network. *Russian Geology and Geophysics* 60 (11), 1319–1325. <https://doi.org/10.15372/RGG2019134>.

Makarov S.A., 2012. Debris-Flows of Pribaikalie. Institute of Geography SB RAS, Irkutsk, 111 p. (in Russian) [Макаров С.А. Сели Прибайкалья. Иркутск: Институт географии СО РАН, 2012. 111 с.].

Mamedov J.H., 2013. Gradation Structure of Flow Deposits and Alluvial Fans and Their Regularities (Based on Torrents of Azerbaijani Part of the Greater Caucasus). *Geographical Bulletin* 4 (27), 40–48 (in Russian) [Мамедов Д.Г. Гранулометрический состав селевых отложений в конусах выноса и их закономерности (на примере селей Азербайджанской части Большого Кавказа) // Географический вестник. 2013. № 4 (27). С. 40–48].

Mikhailov P.G., Lomtev E.A., Analiyeva A.U., Gusmanova M.S., 2016. Development of the Concept of Creation and Functioning of Monitoring Mudflow in the Mountainous and Foothill Areas. *Measuring. Monitoring. Management. Control* 1 (15), 15–23 (in Russian) [Михайлов П.Г., Ломтев Е.А., Аналиева А.У., Гусманова М.С. Разработка концепции создания и функционирования системы мониторинга селеопасности в горных и предгорных районах // Измерение. Мониторинг. Управление. Контроль. 2016. № 1 (15). С. 15–23].

Nosov K.N., 2010. Parameters of Mudflows of the River Baksan Basin. *Prirodoobustroystvo* 4, 50–55 (in Russian) [Носов К.Н. Параметры селевых потоков бассейна реки Баксан // Природообустройство. 2010. № 4. С. 50–55].

Oliferov A.N., 2004. Patterns of Debris Flow Formation in Crimea and the Carpathians. *Scientific Notes of the V.I. Vernadsky Taurida National University. Geography Series* 171 (4), 66–72 (in Russian) [Олиферов А.Н. Закономерности формирования селевых потоков в Крыму и Карпатах // Ученые записки Таврического национального университета им. В.И. Вернадского Серия География. 2004. Т. 171. № 4. С. 66–72].

Puritskis Ya.V., Vershinin V.E., 2023. Development of the Concept of a Multiphase Flowmeter. *Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy* 9 (4 (36)), 76–90 (in Russian) [Пурицкис Я.В., Вершинин В.Е. Классификация режимов многофазных течений методами нейросетевого анализа // Вестник Тюменского государственного университета. Серия: Физико-математическое моделирование. Нефть, газ, энергетика. 2023. Т. 9. № 4 (36). С. 76–90]. <https://doi.org/10.21684/2411-7978-2023-9-4-76-90>.

Rybchenko A.A., Kadetova A.V., Kozyreva E.A., Yuriev A.A., 2019. Experience of Using Non-Specialized Unmanned Aerial Vehicles for Aerial Surveys in the Studies of Exogenous Geological Processes. *Geodynamics & Tectonophysics* 10 (4), 1045–1058 (in Russian) [Рыбченко А.А., Кадетова А.В., Козырева Е.А., Юрьев А.А. Решение тематических задач при изучении экзогенных геологических процессов с применением неспециализированных беспилотных комплексов для аэрофотосъемки // Геодинамика и тектонофизика. 2019. Т. 10. № 4. С. 1045–1058]. <https://doi.org/10.5800/GT-2019-10-4-0457>.

Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The Journal of Machine Learning Research* 15 (1), 1929–1958.

Stepanov B.S., Stepanova T.S., 1991. Debris Flow Mechanics: Experiment, Theory, and Calculation Methods. *Gidrometeoizdat, Moscow*, 379 p. (in Russian) [Степанов Б.С., Степанова Т.С. Механика селей: эксперимент, теория, методы расчета. М.: Гидрометеоиздат, 1991. 379 с.].

Strom A.L., 2022. Grain-Size Composition and Structure of Stony-Avalanche Deposits as a Key to Understanding Their Motion Mechanism. In: *Sergeev Readings. Fundamental and Applied Issues of Modern Soil Science: Proceedings of the Annual Session of the RAS Scientific Council on Problems of Geoecology, Engineering Geology and Hydrogeology* (March 31 – April 1, 2022). *GeoInfo, Moscow*, p. 211–217 (in Russian) [Стром А.Л. Гранулометрический состав и строение отложений каменных лавин – ключ к пониманию механизма их перемещения // Сергеевские чтения. Фундаментальные и прикладные вопросы современного грунтоведения: Материалы годичной сессии Научного совета РАН по проблемам геоэкологии, инженерной геологии и гидрогеологии (31 марта – 1 апреля 2022 г.). М.: ГеоИнфо, 2022. Вып. 23. С. 211–217].

Stupin V.P., Plastinin L.A., Olzoev B.N., 2020. Use of Remote Sensing Data for Medium-Scale Geoinformation Mapping of Debris-Flow Hazard in the Baikal Mountain Country. In: S.S. Chernomorets, K.S. Viskhadzhieva (Eds), *Debris Flows: Disasters, Risk, Forecast, Protection. Proceedings*

of the 6th International Conference (Dushanbe – Khorog, Tajikistan). Vol. 1. "Promotion" LLC, Dushanbe, p. 541–552 (in Russian) [Ступин В.П., Пластинин Л.А., Олзоев Б.Н. Использование данных дистанционного зондирования Земли при среднемасштабном геоинформационном картографировании селевой опасности Байкальской горной страны // Селевые потоки: катастрофы, риск, прогноз, защита: Труды 6-й Международной конференции (Душанбе – Хорог, Таджикистан) / Ред. С.С. Черноморец, К.С. Висхаджиева. Душанбе: ООО «Промоушн», 2020. Т. 1. С. 541–552].

Velikanova L.I., 2014. Short-Term Forecasting of Debris Flow Probability Based on Neural Network Technologies.

Problems of Automation and Control 1 (26), 47–56 (in Russian) [Великанова Л.И. Краткосрочное прогнозирование вероятности схода селя на базе нейросетевых технологий // Проблемы автоматизации и управления. 2014. № 1 (26). С. 47–56].

Yosinski J., Clune J., Bengio Y., Lipson H., 2014. How Transferable Are Features in Deep Neural Networks? In: Z. Ghahramani, M. Welling, C. Cortes, N. Lawrence, K.Q. Weinberger (Eds), Advances in Neural Information Processing Systems. Proceedings of the 28th Annual Conference on Neural Information Processing Systems (December 8–13, 2014, Montreal, Canada). Vol. 27. NeurIPS, p. 3320–3328. <https://doi.org/10.48550/arXiv.1411.1792>.