

УДК 551.243

Засорина Ю. И.

*Научная станция Российской академии наук в г. Бишкеке,
г. Бишкек, Кыргызстан*

МЕТОДЫ ЛАБОРАТОРНОГО И НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ ДЛЯ ИЗУЧЕНИЯ И ВЫЯВЛЕНИЯ РАЗЛОМНЫХ СТРУКТУР

Аннотация. Тянь-Шань представляет собой сейсмически активный транспрессионный орогенный пояс, характеризующуюся высокой сейсмической опасностью. Несмотря на длительную историю исследований, многие разломные структуры в его пределах остаются недостаточно изученными. В настоящей работе приводится обзор современных подходов к идентификации разломов на основе данных дистанционного зондирования Земли, включая цифровые модели рельефа, гиперспектральные данные и температуру поверхности Земли, а также методов машинного обучения и лабораторного моделирования. Лабораторное моделирование рассматривается как самостоятельный инструмент изучения деформаций поверхности, связанных с разломообразованием, так и как потенциальный источник, являющийся основой для алгоритмов машинного обучения. Рассмотренные методы представляют собой интерес для изучения активных разломных структур горных систем подобного типа, где уточнение геометрии разломов имеет важное значение для оценки сейсмической опасности.

Ключевые слова: идентификация разломов, дистанционное зондирование Земли, цифровая модель рельефа, извлечение линеаментов, машинное обучение, лабораторное моделирование.

ЖАРАКА ТҮЗҮЛҮШТӨРҮН ИЗИЛДӨӨДӨ ЖАНА ИДЕНТИФИКАЦИЯЛООДО ЛАБОРАТОРИЯЛЫК АНАЛОГДУК МОДЕЛДӨӨ ЖАНА НЕЙРОНДУК ТАРМАКТАРГА НЕГИЗДЕЛГЕН ЫКМАЛАР

Кыскача мазмуну. Түндүк Тянь-Шань тоосу жогорку сейсмикалык коркунуч менен мүнөздөлгөн, транспрессиялык орогендик система болуп саналат. Изилдөөлөрдүн узак тарыхына карабастан, көптөгөн жарака түзүлүштөрү жетиштүү деңгээлде картага түшүрүлгөн эмес. Бул макалада космостон зонддоо маалыматтарына, санариптик бийиктик моделдерине (DEM), машиналык окутуу ыкмаларына жана лабораториялык аналогдук моделдөөгө негизделген жаракаларды аныктоонун заманбап ыкмалары каралган. Макалада DEM маалыматтарынан алынган морфотектоникалык линеаменттерди, гиперспектралдык сүрөттөрдү, жер бетинин температурасы боюнча маалыматтарды жана жаракаларды автоматтык аныктоо үчүн колдонулган машиналык окутуу алгоритмдерин пайдалануу талкууланат. Лабораториялык аналогдук моделдөө жаракалар менен байланышкан жер бетинин деформацияларын изилдөөнүн өз алдынча куралы катары, ошондой эле машиналык окутуу алгоритмдери үчүн окутуучу маалыматтарды түзүүнүн мүмкүн болгон булагы катары каралат. Каралган ыкмалар окшош тоо системаларындагы активдүү жарака түзүлүштөрүн изилдөө үчүн өзгөчө мааниге ээ, анткени аларды так мүнөздөө сейсмикалык коркунучту баалоо үчүн зарыл.

Негизги сөздөр: жаракаларды аныктоо, космостон зонддоо, санариптик бийиктик модели, линеаменттерди бөлүп алуу, машиналык окутуу, аналогдук моделдөө.

METHODS OF LABORATORY AND NEURAL NETWORK MODELLING FOR THE STUDY AND IDENTIFICATION OF FAULT STRUCTURE

Abstract. Tian Shan is a seismically active transpressional orogenic belt characterized by high level of seismic hazard. Despite a long history of investigation, many fault structures remain

insufficiently mapped. This paper reviews contemporary approaches to fault identification based on remote sensing data, digital elevation data, machine learning methods, and laboratory analogue modelling. This paper discusses the use of DEM-derived morphotectonic lineaments, hyperspectral imagery, land surface temperature data, supervised machine learning algorithms for automated fault detection. Laboratory analogue modelling is considered both as an independent tool for studying fault-related surface deformation and as a potential source of training data for machine learning algorithms. The reviewed methods are of particular relevance for the study of active fault structures in similar mountain systems, where improved fault geometry characterization is essential for seismic hazard assessment.

Keywords: fault identification, remote sensing, digital elevation model, lineament extraction, machine learning, analogue modelling.

Введение. Регион Тянь-Шаня характеризуется высоким уровнем сейсмической опасности, обусловленной передачей тектонических напряжений от зоны продолжающейся коллизии Индийской и Евразийской литосферных плит [1]. В современной парадигме генезиса землетрясений разломные структуры имеют доминирующее значение [2]. В связи с чем детальное изучение разломных структур на базе современных методов анализа (спутниковые данные, искусственный интеллект и др.) открывает новые возможности для понимания геодинамических процессов. Поэтому выявление новых и уточнение прохождения известных активных разломов представляет собой значительный научный и практический интерес.

Несмотря на длительную историю исследований Тянь-Шаня, значительная часть разломных структур региона остаётся недостаточно изученной. Разломы оказывают существенное влияние на формирование рельефа и часто проявляются в виде линейных геоморфологических структур и линеаментов, что позволяет их выявлять по данным цифровых моделей рельефа (ЦМР) и с помощью дистанционного зондирования земли (ДЗЗ).

Методы ДЗЗ, ЦМР расширяют возможности обнаружения и анализа разломов, особенно в труднодоступных районах, снижая затраты времени, финансовых и человеческих ресурсов по сравнению с традиционными полевыми исследованиями. Однако интерпретация дистанционных данных во многом зависит от квалификации исследователя и может содержать элементы субъективности.

Развитие методов машинного обучения (МО) открывает новые возможности для автоматизации процесса идентификации, классификации и детализации разломов. Дополнительным источником данных для обучения алгоритмов может служить лабораторное моделирование процессов разломообразования, позволяющее исследовать влияние тектонических деформаций на морфологию поверхности. Благодаря хорошей выраженности структурных элементов и отсутствию значительных шумов, такие данные представляют интерес для формирования обучающих выборок. В настоящей работе рассмотрены современные подходы к идентификации разломов на основе данных ЦМР, ДЗЗ, методов МО и результатов лабораторного моделирования.

Обзор/Обсуждение. В данной обзорной работе рассмотрены научные публикации, посвящённые лабораторному моделированию процессов разломообразования, а также современным методам идентификации и детализации разломных структур.

Лабораторное моделирование является важным инструментом изучения тектонических процессов, позволяющим воспроизводить деформации земной коры в контролируемых условиях и наблюдать их развитие в ускоренном временном масштабе. Один из ведущих центров лабораторного моделирования находится в университете Монпелье (Франция), где подобные эксперименты проводятся на протяжении более 40 лет. За это время были существенно усовершенствованы экспериментальные установки,

моделирующие материалы и методы мониторинга деформаций [3, 4, 5, 6, 7]. Современные эксперименты воспроизводят такие процессы как хрупкое и пластичное поведение коры, её погружение и поднятие, формирование речных систем, террас, аллювиальных конусов выноса и так далее. Например, при симуляции трёх классических разрывов, были получены ожидаемые для этих тектонических режимов геоморфологические структуры [5]. Примеры полученных геоморфологических маркеров представлены на рисунке 1. Недавние исследования воспроизвели в лабораторных условиях развитие транспрессионных зон и показали, что интенсивность эрозионного воздействия существенно влияет на процессы разломообразования [7]. Несмотря на неизбежное упрощение природных систем, чёткая выраженность структур и минимальный шум делают результаты экспериментов перспективным источником обучающих данных для методов машинного обучения.




Рисунок 1. Результаты лабораторного моделирования [3] для: (а) надвига; (б) сброса; (с) сдвига.

В природных условиях провести идентификацию разломов по геоморфологическим маркерам значительно сложнее: большинство форм рельефа формируются под воздействием нескольких процессов одновременно, однозначная линейная связь между тектоническим процессом и его геоморфологическим проявлением встречается редко, а различные процессы способны формировать схожие формы рельефа [8].

На сегодняшний день ДЗЗ является одним из основных источников цифровой информации о поверхности Земли и традиционным инструментом исследований в геоморфологии и тектонике [9]. Развитие технологий – InSAR, спутниковая и авиационная съёмка, тепловое инфракрасное зондирование, LiDAR – в сочетании с современными методами обработки данных, включая алгоритмы машинного и глубокого обучения существенно расширило возможности изучения тектонических деформаций,

разломообразования и их геоморфологических проявлений. Так, благодаря сочетанию ЦМР и данных ДЗЗ, удалось детализировать геометрию сегмента Северо-Анатолийский разлома, с которым связывают разрушительные землетрясения 1912 года [10].

Для выявления разломов также применяется гиперспектральное ДЗЗ, использующее, например, различия в спектральном отклике почв в зонах разломов, вызванные окислительно-восстановительными процессами с участием соединений железа. Так [11], на примере разлома Балапур (Кашмирская долина, Гималаи) с использованием снимков Nuregon EO-1 показано, что зона разлома обладает выраженными спектральными отличиями, обусловленными полосами поглощения Fe^{3+} и Fe^{2+} ; для разделения спектров по обе стороны разлома авторы применили методы кластеризации и дискретного вейвлет-преобразования.

Для локализации разломов могут использоваться данные температуры поверхности Земли (LST): разломные зоны могут служить каналами переноса тепла к поверхности, формируя тепловые аномалии. Пространственная связь между разломными структурами и зонами повышенных температур подтверждена как на данных Landsat 8 в зоне разлома Жуйли–Лунлин [12], так и в работе индонезийских исследователей, где наблюдалась корреляция между плотностью линеаментов, зонами повышенной трещиноватости и усилением теплового потока [13]. Полученные результаты показали пространственную связь между разломными структурами и зонами повышенных температур, что подтверждает возможность использования данных LST для выявления тектонических нарушений. Поскольку температурные аномалии могут быть вызваны и другими факторами (рельефом, растительностью, влажностью почв), данные LST обычно используют в сочетании с другими признаками разломов.

Извлечение морфотектонических линеаментов из ЦМР является устоявшимся методом идентификации тектонических структур на поверхности Земли [14]. В последние годы широкое распространение получили полуавтоматические подходы, основанные на обработке данных ДЗЗ, при этом методы предварительной обработки данных и последующего выделения линейных структур могут существенно различаться. Для выделения линеаментов широко применяется алгоритм LINE (PCI Geomatica) [15, 16]. В качестве этапов предварительной обработки используются цифровые модели рельефа и методы морфометрического анализа, включая топографический индекс положения (TPI), а также производные рельефа, такие как уклон, экспозиция и высотные градиенты. При этом TPI обеспечивает наилучшую выраженность линейных морфологических элементов, а результаты верифицируются с помощью геологических карт и полевых наблюдений, где это возможно [15, 16]. Альтернативный подход основан на обработке мультиспектральных спутниковых данных с использованием методов компьютерного зрения. В таких работах применяются алгоритмы снижения размерности, включая Minimum Noise Fraction (MNF), фильтры усиления границ, такие как Laplacian, а также методы детекции краев для автоматического выделения линеаментов [17]. Несмотря на различия в методах предварительной обработки и анализа данных, общий рабочий процесс по извлечению линеаментов остаётся сопоставимым и включает последовательные этапы: усиление линейных структур, выделение границ, автоматическое извлечение линеаментов и последующую экспертную интерпретацию и валидацию результатов.

Альтернативный, статистический подход к выявлению структуры разломов предложен в работе [18], где разломы определяются как хребты плотности гипоцентров землетрясений, оцениваемые с помощью модификационного алгоритма mean-shift с учётом локальной матрицы Гессе. Метод был апробирован на сейсмических данных залива Сан-Франциско и показал более точное восстановление известных разломных структур в 2D и 3D по сравнению с рядом альтернативных алгоритмов кластеризации.

В последние годы наблюдается активное внедрение методов машинного и глубокого обучения для повышения объективности и автоматизации анализа геопространственных

данных, а также ускорения их обработки. Предложены комплексные подходы к идентификации разломов [19], объединяющие цифровые модели рельефа, машинное и глубокое обучение, а также многоканальные данные дистанционного зондирования Земли (рисунок 2). Были рассчитаны 16 факторов, характеризующих топографические, спектральные, геоморфологические, структурные признаки, полезные при поиске разломов и представляющие собой растровые слои, рассчитанные из ЦМР. На них были отмечены пункты на и вне уже известных разломов изучаемой области, которые использовались в качестве обучающего набора данных для моделей машинного обучения. В течение этого процесса используются модели глубокого обучения на основе свёрточной нейросети U-Net, удаляют шум, уточняют и сглаживают линии разломов.




Рисунок 2. Методология идентификации разломов на основе данных ДЗЗ, ЦМР и их производных с применением машинного обучения [19].

Авторы приходят к выводу, что наибольшую информативность демонстрируют такие параметры, как TPI, линии долины (valley line – VL), глубина расчленения поверхности (surface cutting depth – SCD) и ДЗЗ (remote sensing imagery – RSI), а наиболее эффективным алгоритмом машинного обучения является метод деревьев классификации и регрессии CARD. Для автоматического распознавания разломов на сейсмических данных предложена архитектура SEU-Net – модификация U-Net с блоками Squeeze-and-Excitation, обеспечивающая адаптивную перекалибровку весов каналов признаков и подавление фонового шума [20]. Гибридный подход к выявлению сетей разломов на 3D сейсмических данных, сочетающий структурные атрибуты с CNN-моделями и двухэтапным трансферным обучением, апробирован на тектонически сложной площади Poseidon 3D (бассейн Браус, Австралия), где автоматическая разметка превзошла ручную по точности и устойчивости модели [21].

Применение модели FCN-ResNet к данным цифровой модели рельефа AW3D30 показало возможность автоматической классификации основных форм рельефа (равнин, платформ, холмов и гор) непосредственно по ЦМР. Добавление производных параметров рельефа, таких как уклон, кривизна, теневой рельеф и степень расчленённости, не привело к существенному повышению точности классификации [22].

Для детального анализа поверхности Земли необходимы ЦМР высокого разрешения. Стандартные данные с разрешением от 30 м не всегда позволяют выявлять геоморфологические особенности. Методы суперразрешения на основе глубокого обучения, в частности модель TfaSR, позволяют повысить детализацию ЦМР с сохранением геоморфологических особенностей рельефа точнее, чем традиционные методы повышения разрешения [23].

Таким образом, современные методы ДЗЗ, ЦМР и МО формируют комплементарную методологическую базу для идентификации разломных структур (Таблица 1). Лабораторное моделирование, в свою очередь, остаётся востребованным инструментом для непосредственного наблюдения процессов разломообразования, и открывает перспективные возможности для формирования обучающих выборок для алгоритмов автоматического распознавания.

Таблица 1 – Систематизация методов, рассмотренных в обзоре.

Метод	Подзадача	Входные данные
Машинное обучение	Идентификация [19, 20, 21]	ЦМР [19], сейсмические данные [20, 21]
	Классификация [19, 22]	ЦМР [19, 22]
	Детализация [19, 23]	ЦМР [19, 23]
Аналитические методы	Локализация [11, 12, 13]	• ДДЗ [10,11,17], LST [12,13]
	Извлечение линеаментов [13, 14, 15, 16, 17]	• ЦМР [10, 14, 15, 16]
	Детализация [10, 18]	• Сейсмические данные [18,21]
Лабораторное моделирование [3, 4, 5, 6, 7]		

ЗАКЛЮЧЕНИЕ

Проведённый анализ литературы показывает, что идентификация разломных структур остаётся нетривиальной задачей из-за сложности геоморфотектонических систем и неоднозначности интерпретации данных. Современные методы ДЗЗ, включая анализ ЦМР, гиперспектральные данные и температуру поверхности Земли, существенно расширяют возможности выявления разломов, особенно в труднодоступных районах.

Внедрение методов машинного и глубокого обучения открывает перспективы автоматизации и повышения объективности этого процесса, однако требует качественных обучающих данных. Лабораторное моделирование процессов разломообразования представляет в этом контексте перспективный источник таких данных, а также самостоятельный инструмент изучения взаимосвязи тектонических деформаций и морфологии поверхности. Описанные подходы представляют интерес для изучения разломных структур Тянь-Шаня – сейсмически активного региона, где уточнение геометрии разломов имеет как научное, так и практическое значение.

ЛИТЕРАТУРА

1. Buslov M. M., De Grave J., Bataleva E., Batalev V. Cenozoic tectonic and geodynamic evolution of the Kyrgyz Tien Shan Mountains: A review of geological, thermochronological and geophysical data // *Journal of Asian Earth Sciences*. — 2007. — Vol. 29. — P. 205–214. — DOI: 10.1016/j.jseaes.2006.07.001.
2. Rebetsky, Yu. L., Kuzikov S. I. Active faults of the northern Tien Shan: Tectonophysical zoning of seismic risk // *Russian Geology and Geophysics*. — 2016. — Vol. 57. — P. 967–983. — DOI: 10.1016/j.rgg.2016.05.004.
3. Malavieille J. Modélisation expérimentale des chevauchements imbriqués: application aux chaînes de montagnes // *Bulletin de la Société géologique de France*. — 1984. — T. XXVI, № 1. — P. 129–138.
4. Graveleau F., Hurtrez J.-E., Dominguez S., Malavieille J. A new experimental material for modeling relief dynamics and interactions between tectonics and surface processes // *Tectonophysics*. — 2011. — Vol. 513. — P. 68–87. — DOI: 10.1016/j.tecto.2011.09.029.
5. Graveleau F., Strak V., Dominguez S., Malavieille J., Chatton M., Manighetti I., Petit C. Experimental modelling of tectonics–erosion–sedimentation interactions in compressional, extensional, and strike–slip settings // *Geomorphology*. — 2015. — Vol. 244. — P. 146–168. — DOI: 10.1016/j.geomorph.2015.02.011.
6. Dominguez S., Sylvain R., Garcia-Estève C., Cattin R., Graveleau F. Physical and Mechanical Properties of a New Analog Material (MAT-V) for Geomorphic Experiments // *Geomorphica*. 2026. Vol. 2, Iss. 2. DOI: 10.59236/geomorphica.v2i1.50
7. Conrad, E. M., Reitano, R., Faccenna, C., Becker, T. W.: Morpho-Tectonics of Transpressional Systems: Insights From Analog Modeling. // *Tectonics*. – 2023 – 42,10 – DOI: 10.1029/2023TC007865
8. Schneevoigt N.J, Schrott L. Linking geomorphic systems theory and remote sensing. A conceptual approach to Alpine landform detection (Reintal, Bavarian Alps, Germany) // *Geographica Helvetica*. – 2006. – 61(3):181-190 – DOI:10.5194/gh-61-181-2006
9. Ren, Z.; Zhang, P.; Oguchi, T.; He, Z. Remote Sensing Perspectives on Geomorphology and Tectonic Processes // *Remote Sensing* – 2023 – 15 (9): 2327 – DOI:10.3390/rs15092327
10. Kaya Ş., Müftüoğlu O., Tüysüz O. Tracing the geometry of an active fault using remote sensing and digital elevation model: Ganos segment, North Anatolian Fault zone, Turkey // *International Journal of Remote Sensing*. — 2004. — Vol. 25, No. 19. — P. 3843–3855. — DOI: 10.1080/01431160310001652394.
11. Dar A. M., Bukhari S. K., Gull D. S. The applications of hyperspectral remote sensing techniques in the identification of subsurface faults. An experimental study // *Remote Sensing Applications: Society and Environment*. — 2023. — Vol. 29. — Art. 100904. — DOI: 10.1016/j.rsase.2022.100904.
12. Chao, J. Detecting geothermal anomalies using Landsat 8 thermal infrared remote sensing data in the Ruili Basin, Southwest China / J. Chao, Z. Zhao, Z. Lai, S. Xu, J. Liu, Z. Li, X. Zhang, Q. Chen, H. Yang, X. Zhao // *Environmental Science and Pollution Research*. — 2022. — DOI: 10.1007/s11356-022-24417-3.

13. Akhyar. Identification of geothermal potential zone associated with land surface temperature derived from Landsat 8 data using split-window algorithm / Akhyar, C. A. Sary // Journal of Applied Research and Technology. — 2024. — Vol. 22, № 1. — P. 125–137.
14. Jordan G., Meijninger B. M. L., van Hinsbergen D. J. J., Meulenkamp J. E., van Dijk P. M. Extraction of morphotectonic features from DEMs: Development and applications for study areas in Hungary and NW Greece // International Journal of Applied Earth Observation and Geoinformation. — 2005. — Vol. 7, No. 3. — P. 163–182. — DOI: 10.1016/j.jag.2005.03.003.
15. Hamann S. J., Baranskaya V. A., Geissler H. W., Baranov V. B., Tsukanov V.N. Digital topographic analysis and lineament interpretation south of the Lena Delta, North Siberia: Landscape expression of its tectonic activity // Geomorphology. — 2024. — Vol. 457. — Art. 109228. — DOI: 10.1016/j.geomorph.2024.109228.
16. Villalta E.M.D.P.; Viña O.A.G.; Larreta E.; Romero C.P.; Mulas M. Lineament extraction from digital terrain derivate model: A case study in the Girón–Santa Isabel basin, South Ecuador// Remote Sensing – 2022 – 14, 5400 – DOI:10.3390/rs14215400
17. Farahbakhsh, E. Computer vision-based framework for extracting tectonic lineaments from optical remote sensing data / E. Farahbakhsh, R. Chandra, H. K. H. Olierook, R. Scalzo, C. Clark, S. M. Reddy, R. D. Müller // International Journal of Remote Sensing. — 2019. — DOI: 10.1080/01431161.2019.1674462.
18. Grillenzoni C. Detection of tectonic faults by spatial clustering of earthquake hypocenters // Spatial Statistics. – 2014. – Vol.7. – P.62-78. – DOI: 10.1016/j.spasta.2013.11.003
19. Guo D., Yang X., Peng P., Zhu L., He H. The intelligent fault identification method based on multi-source information fusion and deep learning // Scientific Reports. — 2025. — Vol. 15. — Art. 6643. — DOI: 10.1038/s41598-025-90823-5.
20. Ren W., Chen X., Zhu X., Bao D., He X., Zhao Y., Zhao M. Fault Identification of Seismic Data Based on SEU-Net Approach // Applied Sciences. – 2025. – Vol.15, № 18. – 10152.- DOI: 10.3390/app15810152
21. Khan M., Bery A.A., Bashir Y., Sharoni S.M.H., Ali S.S. Automated fault network extraction in complex tectonic regimes: A hybrid machine learning and structural attributes approach // Applied Computing and Geosciences. – 2025. – Vol. 27. – 100264. – DOI: 10.1016/j.acags.2025.100264
22. Yang J., Xu J., Lv Y., Zhou C., Zhu Y., Cheng W. Deep learning-based automated terrain classification using high-resolution DEM data // International Journal of Applied Earth Observation and Geoinformation. — 2023. — Vol. 118. — Art. 103249. — DOI: 10.1016/j.jag.2023.103249.
23. Zhang, Y., Yu W., Zhu D. Terrain feature-aware deep learning network for digital elevation model superresolution // ISPRS Journal of Photogrammetry and Remote Sensing. — 2022. — Vol. 189. — P. 143–162. — DOI: 10.1016/j.isprsjprs.2022.04.028.

Рецензент: к.ф.-м.н. Кузиков С. И.