

ISSN 2541-8912 (Print)
ISSN 2713-2161 (Online)

ГЕОСИСТЕМЫ ПЕРЕХОДНЫХ ЗОН



GEOSYSTEMS
of Transition Zones

2023 **Том 7** **№ 1**

Уважаемые авторы, рецензенты и все друзья нашего журнала!

Редколлегия и редакция журнала «Геосистемы переходных зон» благодарят всех, кто содействует журналу в выполнении его миссии – предоставление российским и зарубежным исследователям в области геологии, вулканологии, геофизики, сейсмологии, океанологии, географии, геомеханики, геоэкологии и др. возможности публиковать свои результаты изучения процессов и закономерностей переходных зон Земли.

При вашем заинтересованном участии журнал за шесть лет существования добился заметных успехов. Наблюдаются явные тренды роста основных параметров, по которым обычно оцениваются журналы. Например, повышение импакт-фактора РИНЦ как с учетом цитирования из всех источников, так и по цитированию в журналах ядра РИНЦ; рост числа ссылок в списках литературы в статьях; увеличение цитирования журналов и зарубежных источников и т.д. Это может способствовать повышению привлекательности и авторитета журнала.

Среди наших авторов ученые из Москвы, Петербурга, Екатеринбурга, Иркутска, Новосибирска, Владивостока, Хабаровска, Петропавловска-Камчатского, Южно-Сахалинска и других городов России.

В настоящее время журнал включен в Перечень ВАК по 9 специальностям в соответствии с новой Номенклатурой специальностей.

В конце 2022 г., как известно, ВАК провел оценку по качественным и количественным критериям журналов, входящих в Перечень. Все журналы распределены по коэффициенту научной значимости по категориям К1, К2, К3. Журналы, входящие в базы WoS, Scopus или RSCI, по умолчанию отнесены к К1. Наш журнал вошел во второй квартиль (К2).

Редколлегией принят тип рецензирования двойной слепой – наиболее оптимальный и рекомендуемый для журналов, нацеленных на вхождение в международные научные базы данных. Рецензии у нас в подавляющем большинстве высококвалифицированные. Мы благодарны нашим рецензентам и внутренним, и независимым, за доброжелательную и конструктивную критику, искреннюю заинтересованность в улучшении качества статей.

Журнал придерживается политики открытого доступа. С 2021 г. журнал включен в международную базу научных журналов Directory of Open Access Journals (DOAJ). PDF-файлы с полнотекстовыми версиями материалов, опубликованных в журнале, находятся в открытом доступе на сайте журнала и на сайте eLibrary, с 2022 г. сведения о статьях и ссылки на них размещаются на портале Российских научных журналов. Метаданные научных статей передаются в международные базы DOAJ и CrossRef.

Оформление журнала и сайт соответствуют всем формальным критериям отбора журналов в международные базы данных.

Стратегия развития журнала, по замыслу редколлегии, предполагала его вхождение в МНБД Scopus и/или Web of Sciences. Но известные реалии жизни сделали такое продвижение проблематичным. Как и другие журналы, мы столкнулись с немалыми трудностями. Основная из них состоит в сокращении притока статей и сужении географии авторов.

Редакция надеется, что журналу удастся сохранить контингент надежных авторов, которые привлекут к сотрудничеству коллег и аспирантов и помогут журналу преодолеть препятствия на пути продвижения его в Russian Science Citation Index (RSCI) (составную часть ядра РИНЦ).

Редакция журнала «Геосистемы переходных зон»



НАУЧНАЯ СМЕНА

Русинович Виктор Викторович

В 2019 г. окончил Российской государственной университет нефти и газа им. И.М. Губкина по специальности «Прикладная геология». Работал специалистом отдела геологии международного проекта «Сахалин-1». Решаемые Виктором научные и производственные задачи включали анализ и интерпретацию особенностей геологического строения месторождений нефти и газа, принципов подсчета исходных и остаточных запасов, оценку геологических рисков. Его исследования служили основой планирования и оптимизации траекторий скважин, играли ключевую роль в принятии инвестиционных решений по программам бурения и напрямую влияли на финансовые результаты проекта.

В 2020 г. поступил на очную форму обучения в аспирантуру Института морской геологии и геофизики ДВО РАН, в котором успешно освоил методы ведения научно-исследовательской деятельности и получил новые знания в области промышленной геофизики. Эти знания помогли Виктору в разработке нейронной сети, автоматизирующей процесс трассировки дизъюнктивных нарушений. Помимо этого он сделал существенный вклад в исследование нефтегазонасного потенциала юго-восточной части Присахалинского шельфа, создав модель, воспроизводящую процессы геологической эволюции и катагенетических преобразований материнских пород, миграции и аккумуляции углеводородов осадочного бассейна центральной части Южно-Сахалинской нефтегазонасной области.

В настоящее время продолжает научную деятельность в ИМГиГ ДВО РАН под руководством д.ф.-м.н. Л.М. Богомолова и активном участии к.ф.-м.н. А.С. Закупина, разрабатывая программы, автоматизирующие процессы нефтегазовой отрасли. В результате его работы была создана программа для расчета прогноза добычи нефти и газа, учитывающая ограничения наземного оборудования и требования по эксплуатации добывающих скважин. Программа уже внедрена в производство на проекте «Сахалин-1» и в компании «Транс Нафта Газдобыча». Она в десятки раз сокращает время подготовки прогнозов добычи углеводородов и снижает риск совершения ошибок в расчетах.

Имеет 9 публикаций, в том числе 6 статей в реферируемых российских изданиях. Результаты научной работы апробированы на 10 конференциях, в том числе на 5 международных.

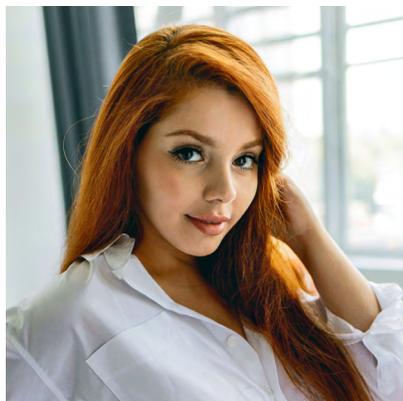


Русинович Лариса Эдуардовна

Окончила Российской государственной университет нефти и газа им. И.М. Губкина по специальности «Прикладная геология» в 2019 г.

С 2020 г. является аспиранткой Института морской геологии и геофизики ДВО РАН по направлению «Геология», ведет научно-исследовательскую деятельность под руководством к.ф.-м.н. А.С. Закупина в сфере оценки перспектив нефтегазонасности Макаровской синклинальной зоны. Эффективно сочетает детерминистические и статистические методы для корректной оценки степени влияния геологических неопределенностей на прогноз нефтегазонасности.

Регулярно принимает участие в конференциях всероссийского и международного уровня.



Автоматизация трассировки поверхностей разломов с помощью алгоритмов компьютерного зрения

В. В. Русинович*, Л. Э. Русинович

*E-mail: victor.rusinovich@gmail.com

Институт морской геологии и геофизики ДВО РАН, Южно-Сахалинск, Россия

Резюме. Представлены результаты адаптации сверточной нейросети U-net к решению задачи трассировки поверхностей разломов на трехмерных кубах сейсмоки. Картирование разломов является одним из этапов интерпретации результатов применения сейсмических методов полевых геофизических работ. Результаты интерпретации используются для построения структурных каркасов геологических моделей, планирования стратегии разработки месторождений, оценки гидродинамической связи объектов разработки, планирования точек заложения скважин, их количества и т.д. Разработанный алгоритм нейронной сети, применяющей алгоритмы компьютерного зрения, позволяет существенно увеличить скорость выделения разломов и снижает риски пропуска разломов в процессе интерпретации. Также рассмотрены проблемы применения нейросети, обученной на синтетическом наборе данных, для решения практических задач. Предложены методы повышения достоверности интерпретации данных, полученных в результате проведения полевых геофизических работ. В частности, при помощи расчета и обработки нейросетью дополнительного куба атрибута когерентности. Дана положительная оценка применимости сверточных нейросетей для решения задач трассировки поверхностей разломов.

Ключевые слова: нейронная сеть, машинное обучение, компьютерное зрение, сверточная нейросеть, автоматизация, выделение разломов, интерпретация сейсмоки

Fault surface tracing automation using computer vision algorithms

Viktor V. Rusinovich*, Larisa E. Rusinovich

*E-mail: victor.rusinovich@gmail.com

Institute of Marine Geology and Geophysics, FEB RAS, Yuzhno-Sakhalinsk, Russia

Abstract. This article presents the results of adapting the U-net convolutional neural network to solving the problem of tracing fault surfaces on 3D seismic cubes. Fault mapping is one of the stages of interpretation of the results of using the seismic methods of field geophysical work. The interpretation results are used to build structural frameworks of geological models, plan field development strategies, assess the hydrodynamic connectivity of reservoirs, plan well locations, their number, etc. The developed neural network algorithm, which uses computer vision algorithms, can significantly increase the speed of faults detection and reduce risk of skipping faults in interpretation process. The problems of using a neural network trained on a synthetic data set for solving practical problems are also considered. Methods for increasing reliability of seismic interpretation are proposed. In particular, by calculating and subsequent processing with neural network an additional volume of the coherence attribute. As a result of the study, a positive conclusion on the applicability of convolutional neural networks for solving problems of tracing fault surfaces is given.

Keywords: neural network, machine learning, computer vision, convolution neural network, automation, fault mapping, seismic interpretation

Для цитирования: Русинович В.В., Русинович Л.Э. Автоматизация трассировки поверхностей разломов с помощью алгоритмов компьютерного зрения. *Геосистемы переходных зон*, 2023, т. 7, № 1, с. 86–94. <https://doi.org/10.30730/gtr.2023.7.1.086-094>; <https://www.elibrary.ru/zzuzky>

For citation: Rusinovich V.V., Rusinovich L.E. Fault surface tracing automation using computer vision algorithms. *Geosistemy perexodnykh zon = Geosystems of Transition Zones*, 2023, vol. 7, no. 1, pp. 86–94. (In Russ., abstr. in Engl.). <https://doi.org/10.30730/gtr.2023.7.1.086-094>; <https://www.elibrary.ru/zzuzky>

Благодарности

Авторы благодарны А.С. Закупину и уважаемым рецензентам за обсуждение результатов исследования и полезные замечания по улучшению статьи.

Acknowledgments

Authors are grateful to Aleksander S. Zakupin and the respected Reviewers for discussing the results of the research and useful comments on improving the article.

Введение

Выделение и трассировка разломов выполняется различными методами, в частности разломы со смещением более 10 м могут быть выделены по результатам интерпретации сейсмических данных среднечастотной (10–100 Гц) сейсморазведки. Это трудоемкий процесс, на который, по опыту авторов, может уходить несколько недель и более, в зависимости от качества сейсмической съемки, размера области исследования, сложности геологического строения и многих других факторов. В связи с этим автоматизация трассировки разломов является актуальной задачей, способной существенно сократить время, которое требуется для выполнения работы.

Традиционно трассировка разломов по данным сейсмической съемки выполняется интерпретатором вручную в специализированном программном обеспечении. Авторы предлагают автоматизировать процесс интерпретации с помощью применения сверточных нейронных сетей, которые уже доказали свою эффективность в сегментации изображений в медицине, промышленности, управлении транспортными средствами, сельском хозяйстве и других сферах. Попытки автоматизировать процесс выделения разломов предпринимались ранее, в частности для этих целей компанией Schlumberger Stavanger Research был разработан алгоритм Ant Tracking [1], позволяющий в некоторых случаях сократить общее время интерпретации разломов в 3 раза и более. Так, при интерпретации разломов с применением алгоритмов Ant Tracking на месторождении Марлим Южное удалось сократить время с десяти дней до трех [2]. Предлагаемая авторами нейронная сеть позволяет сократить срок выполнения работ до нескольких десятков минут.

Методика, результаты и обсуждение

Сверточная нейронная сеть один из популярных видов нейронных сетей глубокого обучения, общая идея работы которых заключается в воспроизведении механизмов работы биологических зрительных систем. Распознавание и классификация объектов нейронами происходит при помощи создания карт при-

знаков, при этом детектируемые признаки на каждом последующем слое становятся все более сложными.

Задача выделения разломов в терминологии алгоритмов компьютерного зрения является задачей бинарной классификации объектов, в рамках которой, после тренировки на обучающем наборе размеченных данных, нейросеть должна будет по набору признаков выделить объекты, относящиеся к разломам. При этом формирование набора признаков, по которым объекты определяются как разломы, нейросеть выполнит самостоятельно в процессе обучения на выборке тренировочных данных, содержащих маски размеченных разломов.

Для решения задачи выбрана архитектура U-net [3], которая была разработана для решения схожей задачи бинарной классификации и создания масок, отображающих положение искомым объектов. В качестве инструментов моделирования архитектуры U-net в роли модели нейронной сети применяются открытые библиотеки OpenCV и Keras совместно с TensorFlow на базе языка программирования Python.

Расчеты выполнялись в среде Google Colaboratory, предоставляющей открытый доступ к ограниченному объему облачных вычислительных мощностей графических и тензорных процессоров, которые необходимы для быстрого выполнения расчетов алгоритмами нейронных сетей.

Адаптированная схема архитектуры U-net представлена на рис. 1. Данная архитектура относится к классу сверточных нейронных из-за применяемых в ней методов. В классической нейронной сети, называемой полносвязной или регрессивной, имеются входной, выходной и скрытые слои, которые представляют собой набор нейронов, связанных друг с другом. Архитектура U-net не содержит полносвязных слоев, а имеет только карты признаков между входным и выходным слоями, а также ядра свертки для получения и укрепления признаков искомым объектов, в данном случае разломов.

Данная архитектура получила свое название из-за характерной формы: в ее левой части происходят поэтапная свертка трехмерного куба сеймики и поиск признаков, соответствующих разломам. В правой части, в случае

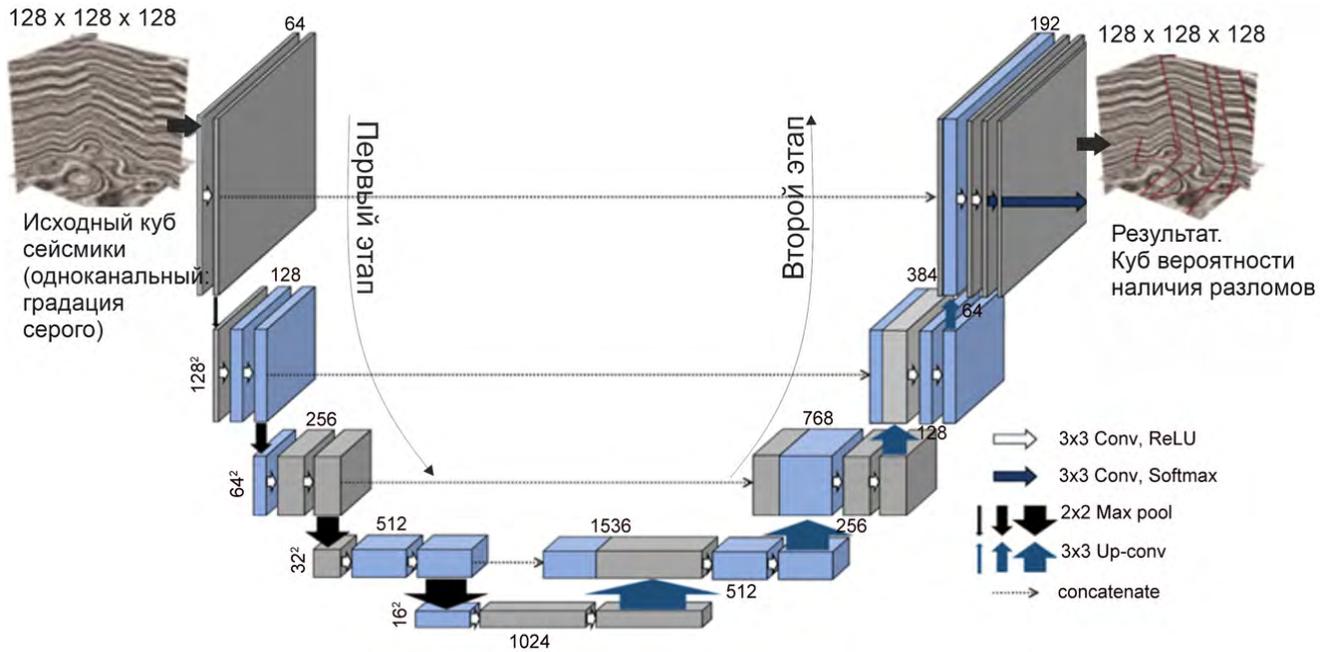


Рис. 1. Архитектура нейронной сети.

Fig. 1. Neural network architecture.

обнаружения разломов, происходит развертка с отображением в соответствующих ячейках вероятности (от 0 до 1) наличия разлома.

Первый этап – понижение дискретизации. Архитектура U-net получает на вход одноканальное трехмерное изображение фиксированного размера, которое является степенью двойки по ширине и высоте, с целью сохранения каждого пиксела при применении к изображению или картам признаков метода понижающей дискретизации (downsampling, иначе pooling). На данном этапе формируются ядра свертки, заполняясь случайными значениями из заранее указанного диапазона. Над поступившим кубом применяются последовательно методы двух сверток и понижения дискретизации. Смысл первого этапа заключается в формировании карт признаков искомым объектов, собранных на разных уровнях сворачивания, благодаря чему данная архитектура способна собирать на изображении признаки искомым объектов, представляющие собой совокупность различных геометрических форм и размеров.

Второй этап – повышение дискретизации, на котором происходит восстановление собранных на первом этапе признаков искомым объектов на изображении. Применяется последовательно метод транспонированной свертки

и конкатенации карт признаков с первого этапа на соответствующем уровне второго этапа. Благодаря этому происходит сбор восстановленных на втором этапе особенностей искомым объектов на изображении (после транспонированной свертки на втором этапе метода), а также особенностей искомым объектов на изображении с первого этапа.

Одним из существенных достоинств данной сети является ее высокая эффективность при обучении на небольшой выборке тренировочных данных, что подтверждено ее использованием в биомедицинских целях, для которых характерна проблема нехватки примеров для обучения моделей [3]. Для обучения нейросети, автоматизирующей трассировку поверхностей разломов, авторы использовали набор из 200 синтетически сгенерированных кубов сеймики (рис. 2) размерами $128 \times 128 \times 128$ пикселей, в связке с размеченными кубами разломов. Еще 20 кубов использовались для валидации результатов. Набор данных был взят из открытых источников [4].

Обучение нейросети проводилось в течение 50 эпох (рис. 3), в процессе поэтапной обработки кубов тренировочных данных, которые последовательно загружались в модель с целью формирования карт признаков для распознавания разломов. Обучение происхо-

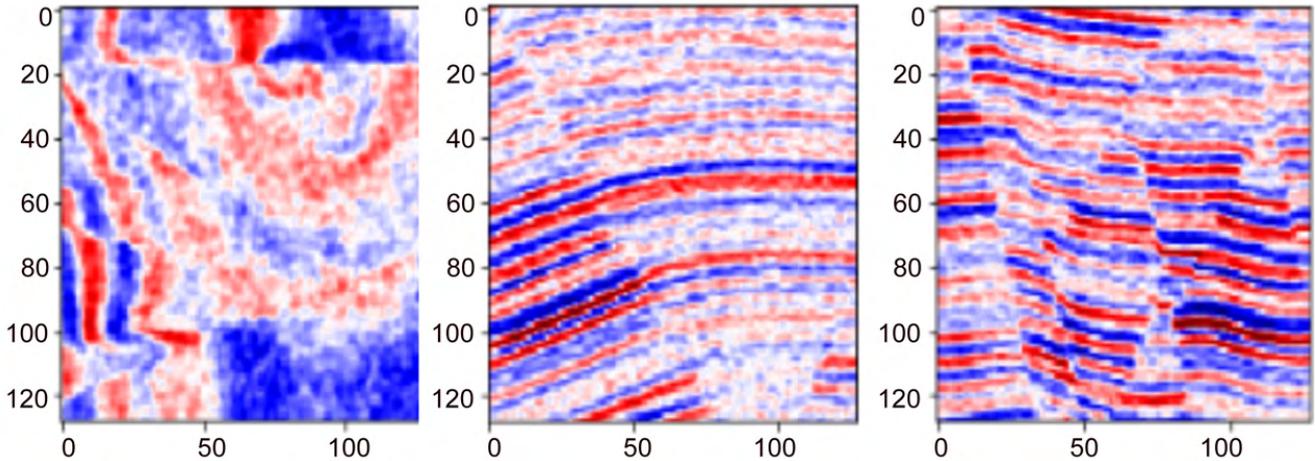


Рис. 2. Пример синтетически сгенерированных кубов сейсмике.
Fig. 2. Examples of synthetic seismic cubes.

дидо путем применения метода обратного распространения ошибки классификации объектов [5], что позволило настроить веса параметров для корректного распознавания разломов. В результате была достигнута точность в 95 % на тренировочных и 93 % на валидационных кубах. Точность считалась как обратная величина ошибки – процент пикселей, соответствующих разломам, которые не были корректно распознаны моделью.

Первичная проверка работоспособности проводилась на тестовых массивах сейсмических данных, которые не использовались для ее тренировки, и сеть успешно выделила разломы (рис. 4). Результирующий куб представляет собой трехмерное пространство, внутри которого отображена вероятность наличия разлома в каждой точке куба. Вероятность представлена диапазоном значений от 0 до 1,

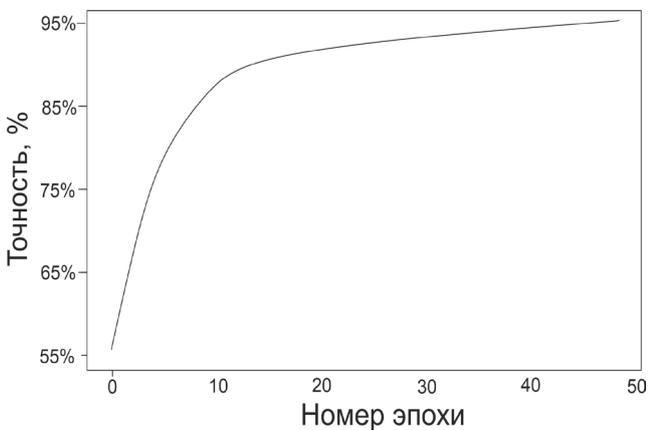


Рис. 3. График зависимости точности модели от количества эпох.
Fig. 3. Graph of model accuracy versus the number of epochs.

отображающим степень достоверности выделения разлома в конкретной точке.

Для тестирования способности нейросети выделять разломы на полевых данных использовались кубы сейсмических данных, взятых из открытых источников: сейсмические данные блока F3 на шельфе Нидерландов [6] и Байкальского месторождения (на суше) [7]. Различия условий геофизических исследований позволяют в полной мере оценить применимость нейросетей, обученных на синтетических данных, трассировать разломы на сейсмических кубах, полученных в результате полевых исследований. Их существенным отличием является подверженность большому количеству как естественных – природных, так и техногенных помех, которые не всегда в полной мере удастся удалить в процессе последующей обработки.

Нейросеть, использующая алгоритмы компьютерного зрения, успешно справилась с задачей бинарной классификации объектов на кубе сейсмических данных блока F3 (рис. 5) размерами 512×312×128 пикселей (исходный куб был обрезан для сокращения времени расчета). Время расчета составило 27 мин. Однако нейросеть классифицировала как разломы отдельные линейные объекты, которые на самом деле являются шумами. В дальнейшем такие объекты можно удалить, добавив дополнительную фильтрацию выходных данных, к примеру, по минимальной длине разрывного нарушения, в результате чего будут удалены все линейные объекты, длина которых меньше заданного значения. Следует отметить

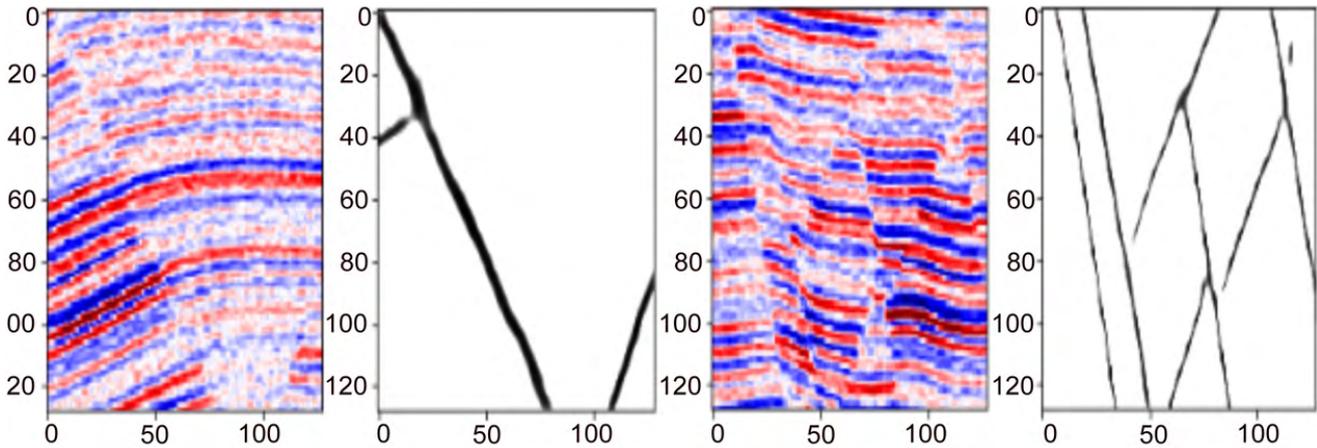


Рис. 4. Пример выделения разломов на кубе синтетической сейсмике (из валидационной выборки).
Fig. 4. Example of faults mapping on synthetic seismic cube (from validation dataset).

высокое качество сейсмике блока F3, что характерно для геофизических исследований, проведенных на шельфе и подверженных меньшему количеству помех по сравнению с наземными исследованиями.

Первая попытка выделения разломов нейросетью на кубе сейсмике Байкальского месторождения (также уменьшенного до размеров 512×384×384 пикселей) не увенчалась успехом из-за значительного количества шумов, которые не были в полной мере удалены в процессе обработки и интерпретировались алгоритмом как разломы (рис. 6). Попытка снизить количество ошибочно интерпретированных разломов за счет удаления всех ячеек с вероятностью наличия разлома менее 0.9 % не привела к значительному улучшению конечных результатов.

Для решения проблемы выделения разломов на Байкальском месторождении были предприняты следующие шаги: 1) был уменьшен диапазон значений амплитуд отражающих горизонтов: с (-15000) – (+15000) до (-6000) – (+6000), с последующим пропорциональным пересчетом всех значений в исходном кубе сейсмике, что повысило контрастность изображения; 2) был рассчитан дополнительный куб когерентности [8], который позволяет выделить несоответствие сигнала по латерали и указывает на неоднородности сейсмического поля, обусловленные влиянием зон разломов [9]. В результате появилась возможность использовать нейросеть для трассировки разломов в массиве данных атрибута когерентности и после применять математические операции для повышения достоверности их распознавания.

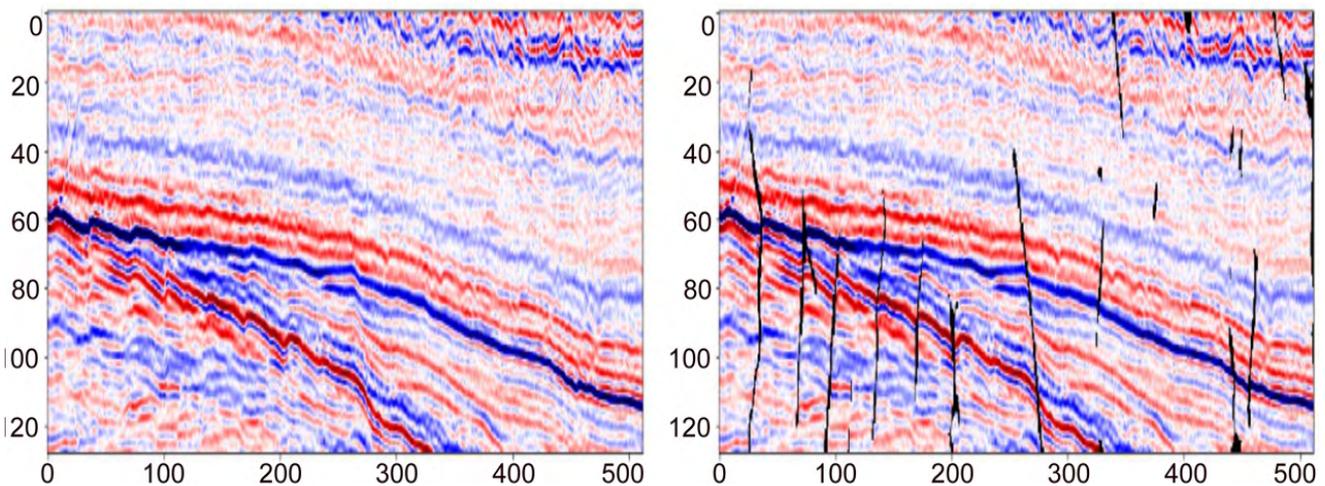


Рис. 5. Пример выделения разломов на кубе сейсмике блока F3 на шельфе Нидерландов.
Fig. 5. Example of fault mapping on the F3 seismic cube on Netherlands shelf.

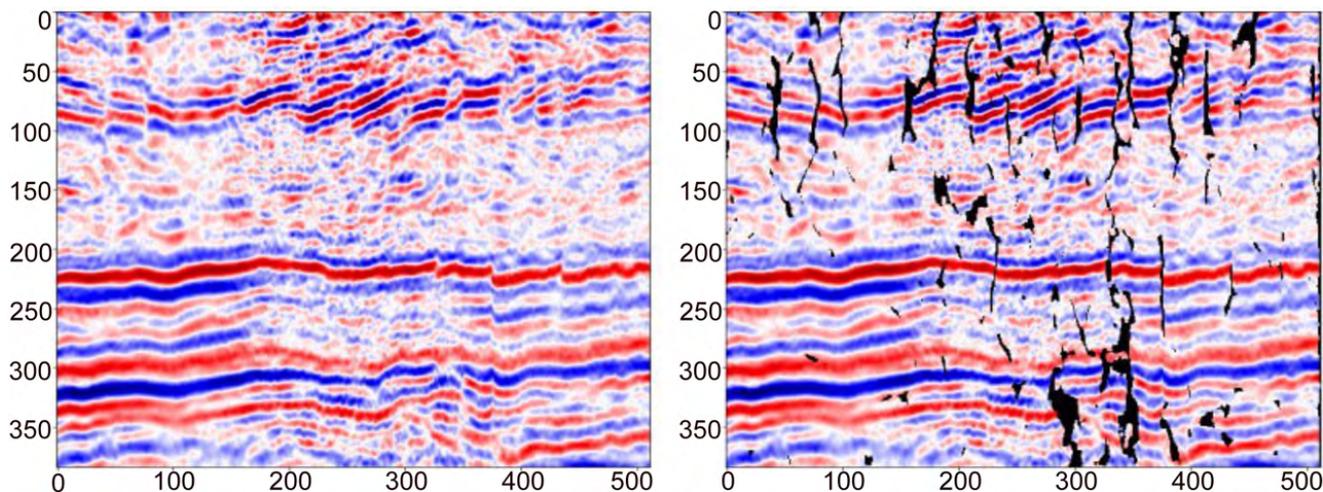


Рис. 6. Пример выделения разломов на кубе сеймики Байкальского месторождения.
Fig. 6. Example of fault mapping on the seismic cube of Baykalskoye field.

После обработки полученных кубов (рис. 7) отмечено повышение качества выделения разломов и уменьшение ошибочно интерпретированных объектов на кубе сеймики. На кубе когерентности результаты распознавания разломов значительно хуже, что объясняется тренировкой модели для трассировки разрывных нарушений на сейсмических кубах.

Наличие дополнительного куба разломов добавляет вариативности дальнейшим преобразованиям. В частности, мы сложили кубы разломов, интерпретированных на кубах сеймики и когерентности, поделили результирующую матрицу на два и удалили все точки с вероятностью наличия разлома менее 0.9 (рис. 8). Таким образом удалось повысить достоверность выявления разрывных нарушений. Недостатком

такого подхода является увеличение времени расчетов в два раза из-за необходимости обработки дополнительного куба.

Обработка нейронной сетью дополнительного куба атрибута когерентности позволяет повысить качество интерпретации разломной тектоники на сейсмических данных низкого качества. Даже увеличенное в два раза (с 27 до 54 мин) время обработки в десятки раз меньше по сравнению с традиционными методами ручной трассировки разломов интерпретаторами, а результат значительно детальней. Традиционно при трассировке разломов интерпретаторы отмечают их на каждом 5-10-15-м сейсмическом изображении, нейронная сеть обрабатывает каждое изображение и точно следует геометрии

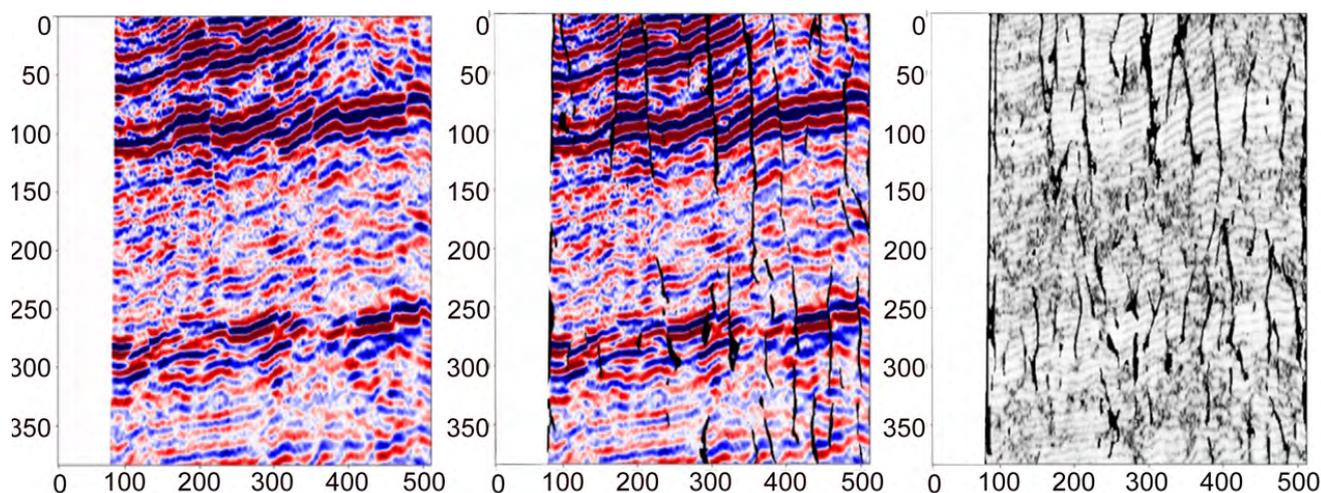


Рис. 7. Пример выделения разломов на пересчитанном кубе сеймики Байкальского месторождения и кубе когерентности.
Fig. 7. Fault mapping on the recalculated seismic cube of the Baykalskoye field and coherence cube.

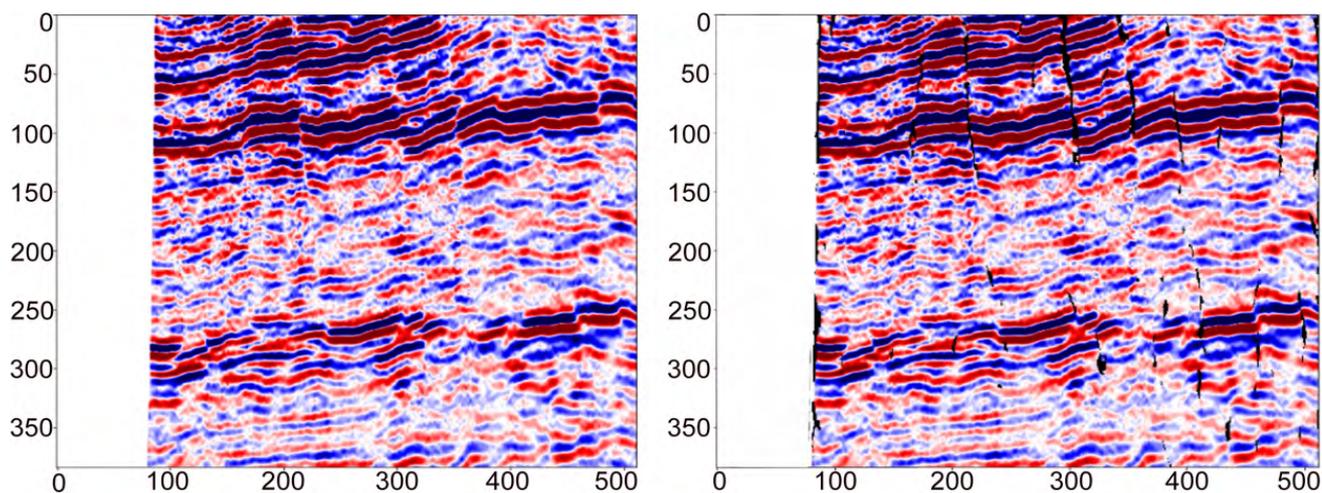


Рис. 8. Результат трассировки разломов после математического преобразования кубов разрывных нарушений, выявленных на кубах сейсмичности и когерентности.

Fig. 8. Result of fault tracing after mathematical transformation of the discontinuity cubes identified on the seismic and coherence cubes.

каждого разлома. Повышение скорости обработки нейронной сетью кубов сейсмических данных может быть достигнуто путем использования более мощных вычислительных процессоров с большим объемом графической памяти. Авторам удалось добиться сокращения времени расчета с 54 до 9 мин путем использования премиумных графических процессоров вместо стандартных.

Выводы

В результате адаптации архитектуры сети U-net к решению задач трассировки поверхностей разломов на кубах сейсмических данных доказана способность нейросетей распознавать разломы. Несмотря на использование синтетических кубов для тренировки нейронной сети, она успешно справилась с задачей распознавания разломов на различных по качеству и условиям проведения геофизических исследований на кубах сейсмических данных.

Авторами выявлена проблема трассировки разломов нейросетью на сейсмических данных, полученных в результате геофизических работ на суше. Такие работы являются более сложными для проведения, чем на шельфе, из-за геоморфологии, транспортной доступности, исходные данные подвержены большему количеству техногенных и естественных помех, которые не всегда в полной мере удается удалить в результате последующей обработки.

Предложены пути решения проблемы: уменьшение диапазона амплитуд для повышения контраста изображения и использование кубов атрибутов, с последующими математическими преобразованиями кубов разломов.

Наличие дополнительных кубов расширяет диапазон возможностей интерпретатора, который может выбрать куб разломов, наиболее точно отражающий существующие дизъюнктивные нарушения, или провести дальнейшие преобразования, в зависимости от целей исследования.

Список литературы

1. Pedersen S.I., Skov T., Randen T., Sønneland L. **2005.** Automatic fault extraction using artificial ants. In: Iske A., Randen T. (eds) *Mathematical methods and modelling in hydrocarbon exploration and production*. Springer, Berlin, Heidelberg, 107–116. (Mathematics in Industry, vol. 7). https://doi.org/10.1007/3-540-26493-0_5
2. Celina C. Silva, Marcolino C.S., Lima F.D. **2005.** Automatic fault extraction using ant tracking algorithm in the Marlim South Field, Campos Basin. In: *SEG Technical Program Expanded Abstracts*, p. 857–860. <https://doi.org/10.1190/1.2148294>
3. Ronneberger O., Fischer P., Brox T. **2015.** U-Net: Convolutional networks for biomedical image segmentation. In: *International Conference on medical image computing and computer-assisted intervention*, p. 17–24. <https://doi.org/10.48550/arXiv.1505.04597>
4. Wu X., Liang L., Shi Yu., Fomel S. **2019.** FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84(3): IM35–IM45 <https://doi.org/10.1190/geo2018-0646.1>
5. Ioffe S., Szegedy Ch. **2015.** Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: *Proceedings of the 32nd International Conference*

on *International Conference on Machine Learning*, 37: 448–456. <https://doi.org/10.48550/arXiv.1502.03167>

Kerry-3D. URL: https://wiki.seg.org/wiki/Open_data#F3_Netherlands (дата обращения 04.11.2022).

7. Кирилова А.С., Закревский К.Е. **2014**. *Практикум по сейсмической интерпретации в Petrel*. М.: МАИ-ПРИНТ, 288 с. URL: <http://www.petroportal.ru/biblioteka> (дата обращения 04.11.2022).
8. Gersztenkorn A., Marfurt K.J. **1999**. Eigenstructure-based coherence computations as an aid to 3-D structural and stratigraphic mapping. *Geophysics*, 64(5): 1468–1479. <https://doi.org/10.1190/1.1444651>
9. Дружинин В.С., Начапкин Н.И., Осипов В.Ю. **2018**. Выделение и картирование глубинных разломов по сейсмическим данным и их проявление в геофизических полях. *Известия УГГУ*, 3(51): 47–53. <https://doi.org/10.21440/2307-2091-2018-3-47-53>

References

1. Pedersen S.I., Skov T., Randen T., Sønneland L. **2005**. Automatic fault extraction using artificial ants. In: Iske A., Randen T. (eds) *Mathematical methods and modelling in hydrocarbon exploration and production*. Springer, Berlin, Heidelberg, 107–116. (Mathematics in Industry, vol. 7). https://doi.org/10.1007/3-540-26493-0_5
2. Celina C. Silva, Marcolino C.S., Lima F.D. **2005**. Automatic fault extraction using ant tracking algorithm in the Marlim South Field, Campos Basin. In: *SEG Technical Program Expanded Abstracts*, p. 857–860. <https://doi.org/10.1190/1.2148294>

Об авторах

Русинович Виктор Викторович (<https://orcid.org/0000-0001-5927-6501>), аспирант, Институт морской геологии и геофизики ДВО РАН, Южно-Сахалинск, Россия, victor.rusinovich@gmail.com

Русинович Лариса Эдуардовна (<https://orcid.org/0000-0003-4146-8868>), аспирантка, Институт морской геологии и геофизики ДВО РАН, Южно-Сахалинск, Россия, larisarusinovich@gmail.com

Поступила 13.01.2023

После доработки 22.02.2023

Принята к публикации 01.03.2023

3. Ronneberger O., Fischer P., Brox T. **2015**. U-Net: Convolutional networks for biomedical image segmentation. In: *International Conference on medical image computing and computer-assisted intervention*, p. 17–24. <https://doi.org/10.48550/arXiv.1505.04597>
4. Wu X., Liang L., Shi Yu., Fomel S. **2019**. FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84(3): IM35–IM45 <https://doi.org/10.1190/geo2018-0646.1>
5. Ioffe S., Szegedy Ch. **2015**. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: *Proceedings of the 32nd International Conference on International Conference on Machine Learning*, 37: 448–456. <https://doi.org/10.48550/arXiv.1502.03167>
6. *Kerry-3D*. URL: https://wiki.seg.org/wiki/Open_data#F3_Netherlands (дата обращения 04.11.2022).
7. Kirilova A.S., Zakrevskiy K.E. **2014**. *Workshop of seismic interpretation in Petrel*. Moscow: MAI-PRINT, 288 p. (In Russ). URL: <http://www.petroportal.ru/biblioteka> (accessed 04.11.2022).
8. Gersztenkorn A., Marfurt K.J. **1999**. Eigenstructure-based coherence computations as an aid to 3-D structural and stratigraphic mapping. *Geophysics*, 64(5): 1468–1479. <https://doi.org/10.1190/1.1444651>
9. Druzhinin V.S., Nachapkin N.I., Osipov V.Yu. **2018**. Identification and mapping of deep faults based on seismic data and their display in geophysical fields. *Izvestiya UGGU = News of the Ural State Mining University*, 3(51): 47–53. (In Russ.). <https://doi.org/10.21440/2307-2091-2018-3-47-53>

About the Authors

Rusinovich, Viktor V. (<https://orcid.org/0000-0001-5927-6501>), Postgraduate Student, Institute of Marine Geology and Geophysics of the Far Eastern Branch of RAS, Yuzhno-Sakhalinsk, Russia, victor.rusinovich@gmail.com

Rusinovich, Larisa E. (<https://orcid.org/0000-0003-4146-8868>), Postgraduate Student, Institute of Marine Geology and Geophysics of the Far Eastern Branch of RAS, Yuzhno-Sakhalinsk, Russia, larisarusinovich@gmail.com

Received 13 January 2023

Revised 22 February 2023

Accepted 1 March 2023