

УДК 550.834.05

DOI 10.31087/0016-7894-2021-3-123-136

## Картирование тектонических нарушений на основе машинного обучения и нейронных сетей

© 2021 г. | Р.Ф. Мифтахов<sup>1</sup>, П.А. Авдеев<sup>1</sup>, Г.Н. Гогоненков<sup>2</sup>, А.К. Базанов<sup>1</sup>, И.И. Ефремов<sup>1</sup>

<sup>1</sup>ООО «ГридПоинт Дайнамикс», Москва, Россия; r.miftakhov@geoplat.com; p.avdeev@geoplat.com; a.bazanov@geoplat.com; i.efremov@geoplat.com;

<sup>2</sup>ФГБУ «Всероссийский научно-исследовательский геологический нефтяной институт», Москва, Россия; gogonenkov@vnigni.ru

Поступила 02.04.2021 г.

Доработана 15.04.2021 г.

Принята к печати 21.04.2021 г.

**Ключевые слова:** сейсмическая интерпретация; тектонические нарушения; автоматизация; искусственный интеллект; машинное обучение; глубокие нейронные сети; методика; программный комплекс (система).

**Аннотация:** Этап построения тектонических нарушений в цикле работ сейсмической интерпретации является одним из самых важных. Кроме того, процесс прослеживания нарушений — весьма трудоемкий, требующий большого объема времени и человеческих ресурсов. На сегодняшний день существует большое число технологических аналитических решений, направленных на автоматизацию процесса трассирования поверхностей разломов, однако большинство из них обладает серией ограничений, обусловленных невозможностью полноценной автоматизации процедур при работах в условиях сложной геологической обстановки района исследований, а также с сейсмическим материалом низкого качества. Таким образом, вопрос оптимизации данного процесса по-прежнему актуален для производственного цикла нефтегазовых и сервисных компаний. В статье рассмотрены результаты нового подхода к реализации процесса автоматизированного картирования тектонических нарушений, основанного на применении искусственного интеллекта через машинное обучение и глубокие нейронные сети. Новые алгоритмы, реализованные в составе программной системы Geoplat Seismic Interpretation, позволяют максимально исключить субъективизм и существенно сократить затраты времени на структурную интерпретацию нарушений в различных геологических условиях.

Для цитирования: Мифтахов Р.Ф., Авдеев П.А., Гогоненков Г.Н., Базанов А.К., Ефремов И.И. Картирование тектонических нарушений на основе машинного обучения и нейронных сетей // Геология нефти и газа. — 2021. — № 3. — С. 123–136. DOI: 10.31087/0016-7894-2021-3-123-136.

## Mapping of faults based on machine learning and neural networks

© 2021 | R.F. Miftakhov<sup>1</sup>, P.A. Avdeev<sup>1</sup>, G.N. Gogonenkov<sup>2</sup>, A.K. Bazanov<sup>1</sup>, I.I. Efremov<sup>1</sup>

<sup>1</sup>Gridpoint Dynamics, Moscow, Russia; r.miftakhov@geoplat.com; p.avdeev@geoplat.com; a.bazanov@geoplat.com; i.efremov@geoplat.com;

<sup>2</sup>All-Russian Research Geological Oil Institute, Moscow, Russia; gogonenkov@vnigni.ru

Received 02.04.2021

Revised 15.04.2021

Accepted for publication 21.04.2021

**Key words:** seismic interpretation; faults; automation; Artificial Intelligence; machine learning; deep neural network; technique; software system.

**Abstract:** The stage of faults construction is one of the most important in a seismic interpretation cycle. Moreover, a process of fault tracking is rather time consuming and require a lot of human resources. Today, there are many technological analytical solutions aimed at automating the process of tracking the fracture surfaces. However, most of them have a number of limitations resulting from the fact that full automation of procedures in the work under the complicated geological conditions of the study area, as well as having low-quality seismic material is impossible. Thus, the problem of optimization of this process is still relevant for the production cycle of oil and gas and service companies. The paper discusses the results of the new approach to implementation of the fault automated mapping process based on the use of Artificial Intelligence through machine learning and deep neural networks. New algorithms implemented in the Geoplat Seismic Interpretation software system allow eliminating subjectivity as much as possible and considerably reduce time for structural interpretation of faults under different geological conditions.

For citation: Miftakhov R.F., Avdeev P.A., Gogonenkov G.N., Bazanov A.K., Efremov I.I. Mapping of faults based on machine learning and neural networks. *Geologiya nefiti i gaza*. 2021;(3):123–136. DOI: 10.31087/0016-7894-2021-3-123-136. In Russ.

## Введение

Основным методом изучения геологического строения осадочных бассейнов является сейсмическая разведка. Ее современные модификации представляют интерес для поиска УВ-скоплений, позволяют с высокой детальностью и на всю глубину выполнить структурные построения по серии отражающих поверхностей, в благоприятных условиях осуществить прогноз литологического состава пород и выделить аномалии, отвечающие ловушкам нефти и газа. Высокая информативность сейсмической разведки определяется огромным объемом информации от каждой точки изучаемой среды на основе применения мощных интерференционных систем наблюдений с последующей глубокой цифровой обработкой данных, позволяющих выделить полезные сигналы от целевых границ на фоне множества разнообразных помех. Завершающим этапом сейсмической разведки является интерпретация результатов — переход от полученного волнового поля к построению структурной модели геологической среды и прогнозу параметров целевых пластов. Несмотря на то, что многие этапы интерпретации сейсмических данных выполняются с широким применением автоматизированных алгоритмов, целый ряд процедур интерпретации осуществляется в значительной мере субъективно и требует больших затрат времени на выполнение ручной работы, особенно в сложных геологических условиях. К числу наиболее сложных задач интерпретации относится выделение и пространственное картирование тектонических нарушений. Неоднократно предпринимались попытки создать автоматизированные средства для картирования тектонических нарушений. На первом этапе для решения задачи привлекались атрибуты сейсмической записи, характеризующие потерю непрерывности времени прихода и формы сейсмических отражений, такие как когерентность, изменение градиента или производной от отражающей поверхности, различные параметры кривизны, локальное изменение амплитуды отражений [1, 2].

Идеология работы аналитических алгоритмов автотрассирования может иметь следующий вид (рис. 1).

Входные данные — кубы исходных сейсмических трасс — подвергаются серии процедур дополнительной обработки и транспонируются в кубы специализированных атрибутов, основанных на когерентности сигнала и других признаках, связанных с разрывами в трассах, свидетельствующих о возможном местоположении разлома. Далее с применением разнородной аналитики происходит «извлечение» разломов в виде «стиков» или поверхностей. Однако следует отметить, что все практические реализации данного подхода обладают рядом принципиальных сложностей, среди которых основными являются:

- ограничения, связанные с качеством исходного материала (некачественная обработка, «зашумленность» съемки и т. д.);

- усложненный этап подготовки исходных данных и настройки алгоритма (дообработка, подбор параметров и т. д.);

- необходимость постпроцессинга результата расчетов (фильтрация, ручное редактирование, объединение разломов и т. д.).

По сути все вышеперечисленные недостатки в большинстве случаев обусловлены ограниченностью и неустойчивостью структурной атрибутики к качеству исходного сейсмического материала и не имеют абсолютного аналитического решения.

На рис. 2 представлен разрез куба когерентности и выделение на его основе тектонических нарушений, демонстрирующие указанную проблематику.

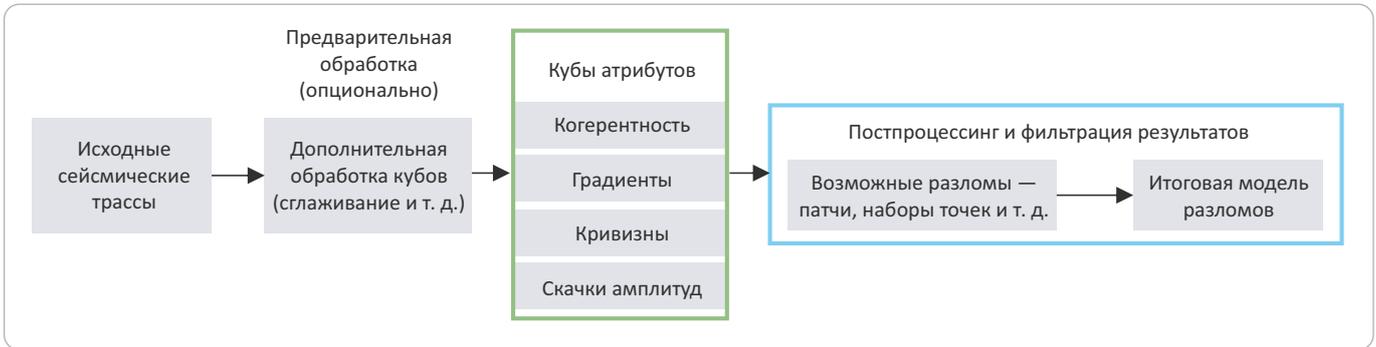
Серия крупных сдвиговых нарушений уверенно опознается визуально на временном разрезе, однако под влиянием серии шумовых эффектов мы имеем разрез когерентности низкого качества и детальности и, как следствие, некорректный результат автотрассирования, явные ошибки при прослеживании нарушений, отсутствие какой-либо закономерности в общей картине разрывов.

Новые подходы к решению задачи выделения тектонических нарушений по сейсмическим данным были найдены в области искусственного интеллекта путем применения машинного обучения и глубоких нейронных сетей. Появившиеся на рубеже столетий новые методы анализа больших массивов данных с применением искусственного интеллекта, основанные на принципах работы человеческого мозга, породили множество областей их практического применения, в том числе и при анализе результатов геофизических наблюдений.

Некоторых специалистов смущает замена давно применяемых алгоритмов анализа данных, основанных на ясных физических предпосылках и строгих математических расчетах, на не очень понятные алгоритмы искусственного интеллекта. Но мозг человека успешно оперирует такими алгоритмами. Нам не нужно задумываться, почему и как мы легко отличаем одного человека от другого и в то же время редко ошибаемся, опознавая знакомого даже спустя много лет и видя его в профиль или в фас. Наш мозг еще в глубоком детстве автоматически находит набор признаков, позволяющих различать людей и безошибочно узнавать своих близких. Мы не знаем, какие это признаки, но оказывается, что их можно и не знать, но успешно решать задачу распознавания. Точно так и работают алгоритмы искусственного интеллекта. На основе анализа большого объема обучающих данных, где задача решена и показаны объекты, которые желательно выявить в данных, машина обучается, т. е. находит неизвестный нам набор признаков, по

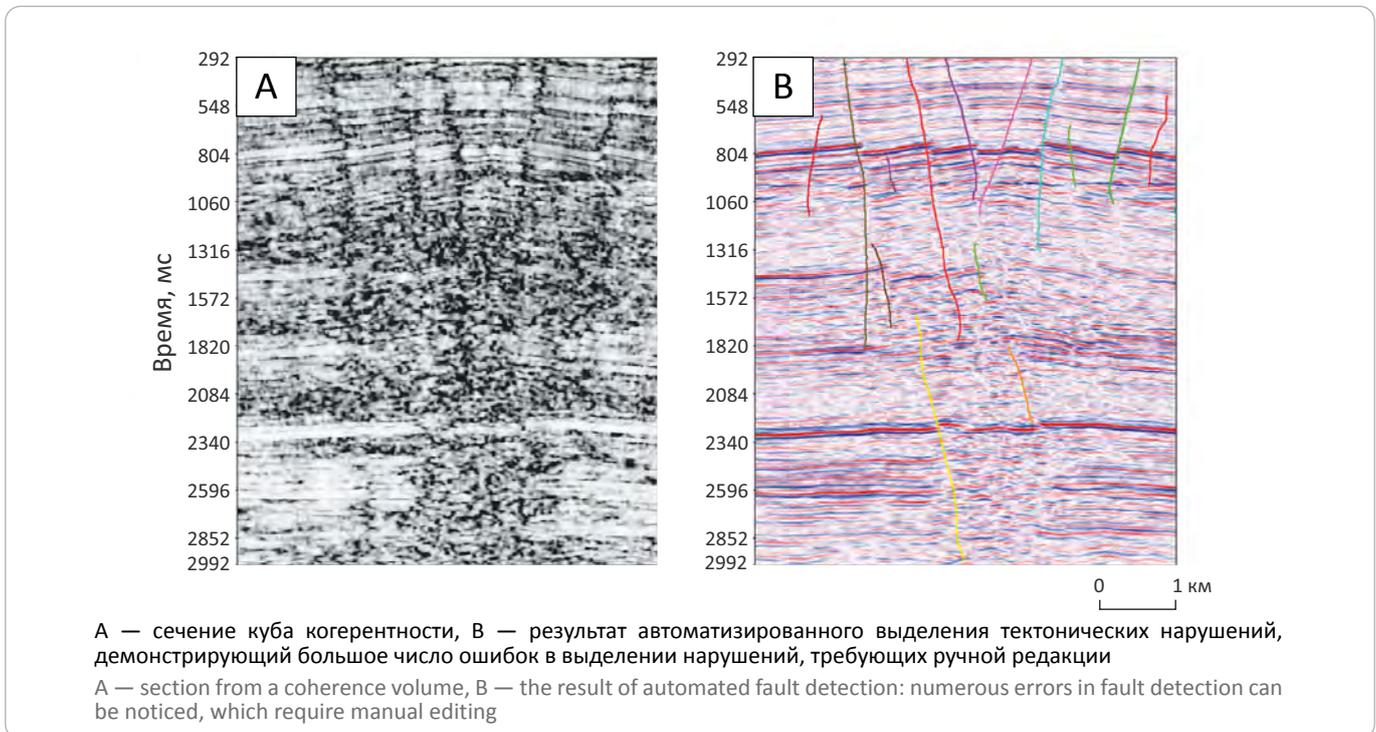
**Рис. 1.** Традиционная схема решения задачи автотрассирования нарушений

**Fig. 1.** Conventional workflow for fault autotracking



**Рис. 2.** Иллюстрация ограниченных возможностей автоматизированного выделения нарушений по атрибутам сейсмических отражений

**Fig. 2.** Illustration of limitations of automated fault detection using seismic reflection attributes



которым она с высокой вероятностью успеха решает задачу выделения искомым объектов по новой совокупности данных. Математическим аппаратом, позволяющим решать такого рода задачи, являются глубокие нейронные сети.

За последние годы опубликован ряд успешных результатов применения искусственного интеллекта в самых разных задачах обработки и интерпретации геолого-геофизических данных: при подавлении помех на сейсмических разрезах, при корреляции отраженных волн и каротажных данных, при инверсии сейсмических разрезов, при фациальном анализе [3–6]. В том числе представлены примеры картирования тектонических нарушений [7–9]. В настоящей статье описаны результаты создания ме-

тодики и программного комплекса, основанного на принципах искусственного интеллекта, для решения задачи автоматизированного картирования тектонических нарушений на данных сейсмозвездки 2D/3D и некоторые результаты его применения в различных геологических условиях. Комплекс реализован в рамках отечественной интерпретационной программной системы Geoplat Seismic Interpretation.

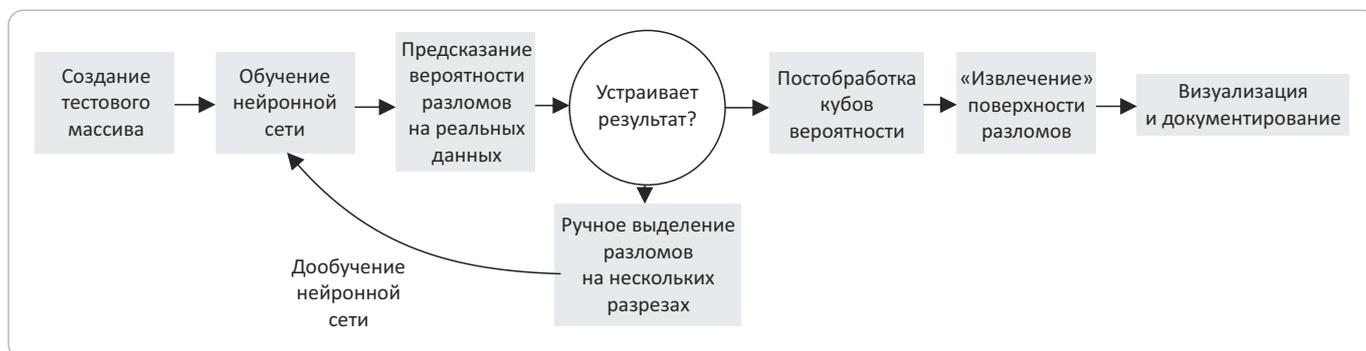
**Обобщенная технология решения задачи картирования нарушений на сейсмических данных 2D и 3D**

Решение задачи реализовано по принципу предварительного обучения нейронной сети на большой совокупности модельных примеров тектонических



## METHODOLOGICAL AND TECHNOLOGICAL ISSUES

**Рис. 3.** Обобщенная схема реализации новой технологии  
**Fig. 3.** General chart of the new technology implementation



нарушений и последующего применения этой сети к реальным сейсмическим данным для автоматизированного выделения нарушений. Модельные примеры представляют собой искусственные фрагменты сейсмической записи с разными вариантами тектонических нарушений. На данных 2D и 3D задача решается аналогичным образом, только в первом случае модельные примеры — это отдельные сечения волнового поля, во втором случае генерируется большая совокупность 3D-сегментов. Поскольку на данных 3D картирование тектонических нарушений является очень трудоемкой и сложной задачей, именно этот вариант описан в настоящей статье.

Отказ от использования реальных данных на этапе предварительного обучения нейронной сети обусловлен целой серией факторов: необходимостью качественного предварительного ручного выделения разломов по каждому набору данных, ограниченностью набора доступных открытых данных и, в особенности, невозможностью однозначной верификации результата предсказания зон разломов ввиду неоднозначности ручного выделения, которая характерна для большого числа реальных производственных проектов.

В то же время использование синтетических наборов данных (датасетов) на данном этапе снимает большинство вышеуказанных ограничений: разметка зон разломов выполняется уже на этапе их генерации, соответственно, каждый разлом отличается точностью описания, что позволяет однозначно верифицировать результат предсказания. Помимо прочего, при создании тестовых синтетических моделей реализована возможность комбинирования более 200 степеней свободы формирования модельных разрезов и нарушений, что позволяет получать на выходе сотни тысяч уникальных вариативных моделей сейсмической волновой картины.

Обобщенная схема реализации новой технологии приведена на рис. 3.

Первым этапом работы является генерация большой совокупности модельных сегментов сейсмического волнового поля, на которых будет прохо-

дить обучение выбранной нейронной сети. Каждый сегмент представлен набором квазипараллельных отражающих границ, нарушенных одним или несколькими разломами. Для качественного обучения сети необходима генерация тысяч или десятков тысяч элементарных 3D-сегментов с произвольным набором отражающих границ и нарушениями, проходящим под любыми азимутами и заданным диапазоном углов наклона. На рис. 4 приведены примеры модельных сегментов, на которых осуществляется обучение нейронной сети. Тысячи таких случайным образом сгенерированных сегментов и составляют обучающую совокупность, которая может быть дополнительно усложнена наложением случайного шума или регулярных помех.

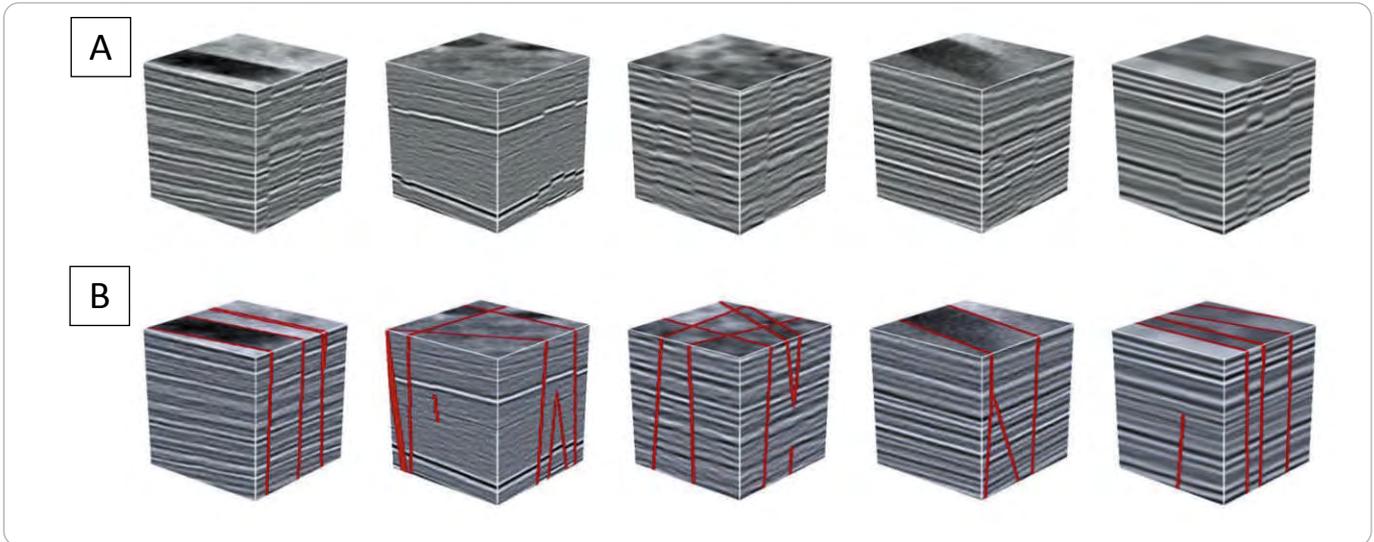
Следующим этапом является обучение нейронной сети на данных тестового массива. На сегодня в литературе описано множество видов нейронных сетей. В данном случае в качестве основы выбираются нейронные сети, которые оказались наилучшими для анализа сегментированных изображений. Это сети из категории ResNet и Unet, которые могут иметь большое число архитектурных параметров для подбора. Подбор параметров производится исходя из баланса предсказательной способности нейронной сети, скорости обучения и требуемых вычислительных ресурсов для предсказания.

В данном случае была выбрана нейронная сеть архитектуры Unet. Предсказательную способность измеряли на выделенном наборе данных из обучающей выборки (синтетический набор данных) и на реальных данных, которые были проинтерпретированы опытными геофизиками. Подбирали такие параметры, как глубина нейронной сети, число резидуальных блоков, число фильтров, параметры оптимизатора и функцию потерь.

В процессе обучения нейронная сеть запоминает набор признаков и закономерностей, характерных для объекта поиска, и на выходе учится предсказывать решение. Далее верифицируем результат: если предсказание полностью совпадает с исходной моделью нарушений — обучение прошло корректно, если нет, то повторяем процесс обучения. Идеальный

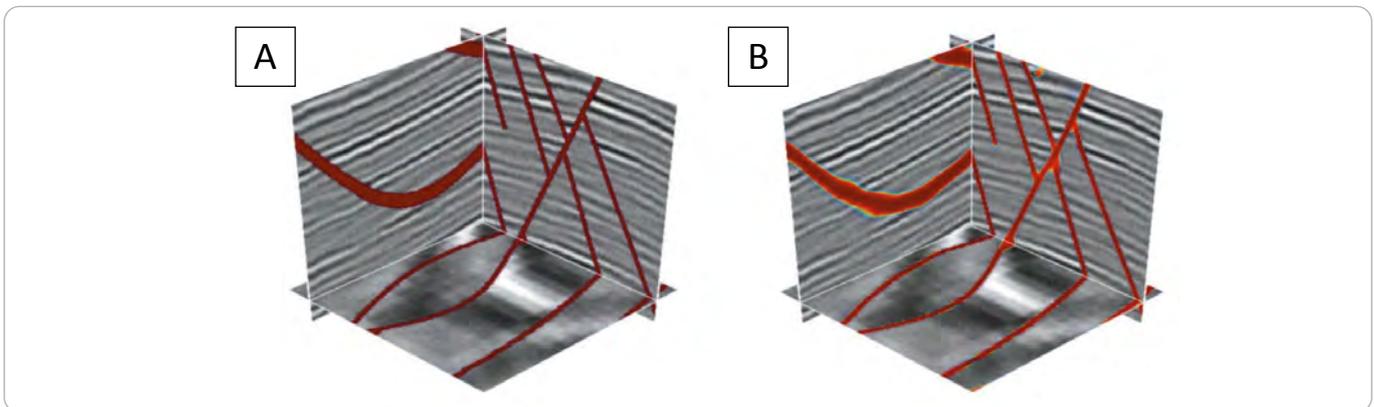
**Рис. 4.** Примеры случайным образом сгенерированных модельных фрагментов сейсмической записи с тектоническими нарушениями без интерпретации (А) и с наложением заданных тектонических нарушений (В)

**Fig. 4.** Examples of randomly generated model segments of seismic record with faults: with no interpretation (A) and with laid-over predetermined faults (B)



**Рис. 5.** Сопоставление исходно заданных тектонических нарушений (А) и результата их предсказания обученной нейронной сетью (В)

**Fig. 5.** Comparison of the predetermined faults (A) and the result of their prediction using the trained neural network (B)



результат предсказания показан на рис. 5 — полное соответствие с исходной разметкой.

Следующий этап является основным — определение вероятности присутствия разлома в каждой точке анализируемых реальных данных. Реальные данные автоматически разбиваются на серию сегментов, аналогичных сегментам обучающего массива, и по набору признаков, сформированных в процессе обучения, программа рассчитывает вероятность присутствия разлома в каждой точке элементарного сегмента. Сечения объемного поля вероятности разломов визуализируются и анализируются интерпретатором. В качестве примера на рис. 6 показан результат первичного выделения вероятности разломов на сечении сейсмического куба 3D. Кроме четкого выделения явно видимых тектонических

нарушений наблюдаются зоны вероятности присутствия разломов, нуждающиеся в дополнительном редактировании.

#### Дообучение нейронной сети

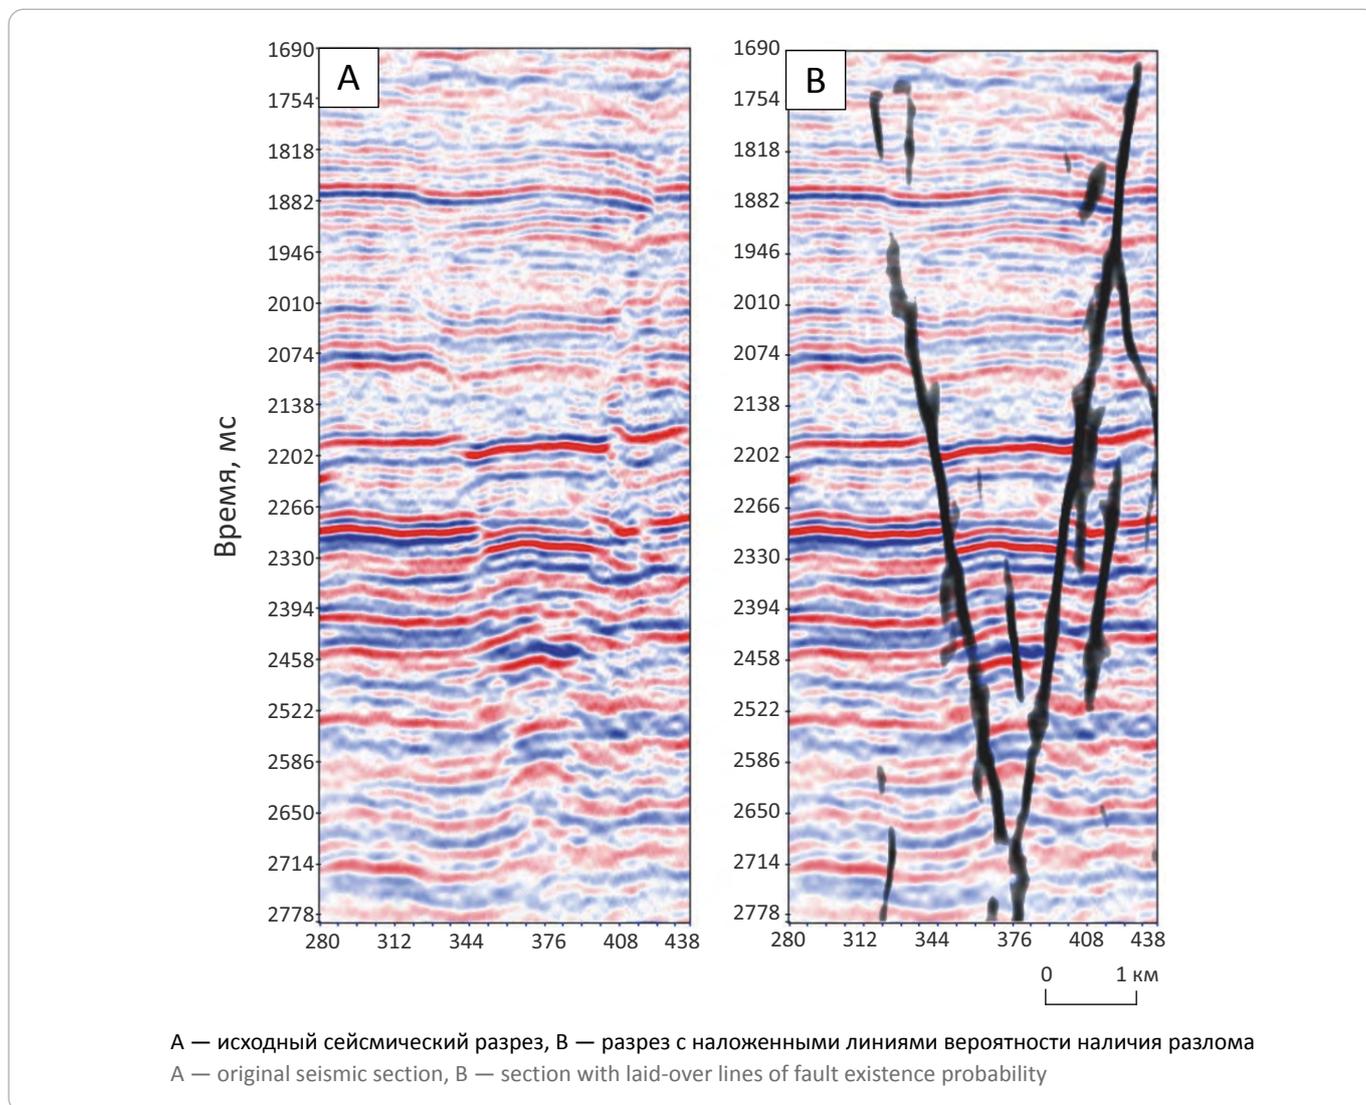
Если результаты выделения разломов удовлетворяют интерпретатора, запускаются следующие этапы обработки поля вероятности разломов. Если результаты не вполне удовлетворительны (см. рис. 6), нейронные сети дообучаются путем ручного выделения разломов на нескольких сечениях интерпретируемого сейсмического куба. Эти данные добавляются в обучающую совокупность, и сеть дообучается. Желательно максимально точно разметить разломы, чтобы при дообучении в нейронной сети не накапливались ошибки. Одной-двух итераций дообучения бывает достаточно, чтобы получить желаемые



## METHODOLOGICAL AND TECHNOLOGICAL ISSUES

**Рис. 6.** Иллюстрация первичного выделения вероятности разломов на вертикальном сечении реальных сейсмических данных 3D

Fig. 6. Illustration of the initial identification of fault probability in vertical section of live 3D seismic data



результаты выделения разломов. Возможность дообучения нейронной сети открывает пути к решению задачи автоматизации этапа трассирования разломов высокой степени сложности: многоступенчатые надвиги, листрические разломы и т. д. На рис. 7 приведен фрагмент сечения куба вероятностей до и после дообучения на фоне интерпретируемого сейсмического разреза. На фрагменте до дообучения яркими линиями показано ручное выделение разломов, которое затем использовалось для дообучения нейронной сети. Сечение куба вероятности разломов после дообучения практически не содержит значимых ошибок.

На рис. 8 показаны результаты дообучения сети на 3D-проекте реальных данных, где потребовалось откоррелировать нарушения вручную всего на двух сечениях куба вкрест простирания основных нару-

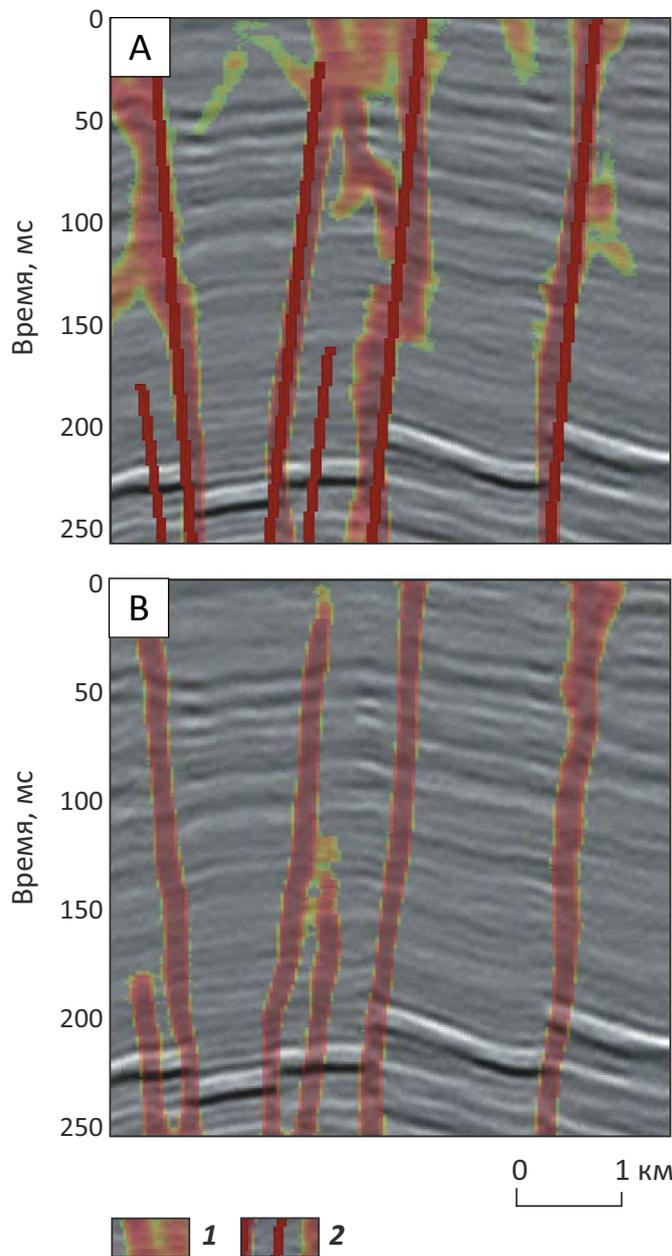
шений и получить значимое улучшение качества их прослеживания.

### Постпроцессинг куба вероятности разломов

Сами по себе кубы вероятности отличаются высокой степенью точности прогнозирования зон вероятного присутствия разлома. Однако данный куб представляет собой совокупность точек определения вероятности разломов, из которых еще необходимо сформировать их искомые поверхности. Кроме того, практически всегда возникает необходимость дополнительной корректировки выделяемых разломов по ряду причин:

– наличие участков «ложной вероятности», где анализ волновой картины не предполагает явных признаков разлома, однако на атрибуте такие зоны отмечены высокой вероятностью нарушений;

**Рис. 7.** Иллюстрация эффекта дообучения сети  
**Fig. 7.** Illustration of network transfer-learning effect



A — фрагмент сечения куба 3D с наложенным сечением куба вероятности разломов (1) и ручным выделением разломов (2), используемых для дообучения сети; B — сечение куба вероятности разломов после дообучения  
 A — fragment of 3D volume section with a laid-over section from fault probability volume (1) and manual fault tracking (2), used for network transfer learning; B — section of fault probability volume after transfer learning

– наличие вероятностей, которые являются проекциями зон вероятностей разлома, качественно прослеживаемого на поперечном направлении;

– фрагментарное отображение некоторых протяженных разломов и необходимость корректировки их вертикальной протяженности.

Переход от куба вероятности присутствия разломов к выделению собственно разломов осуществля-

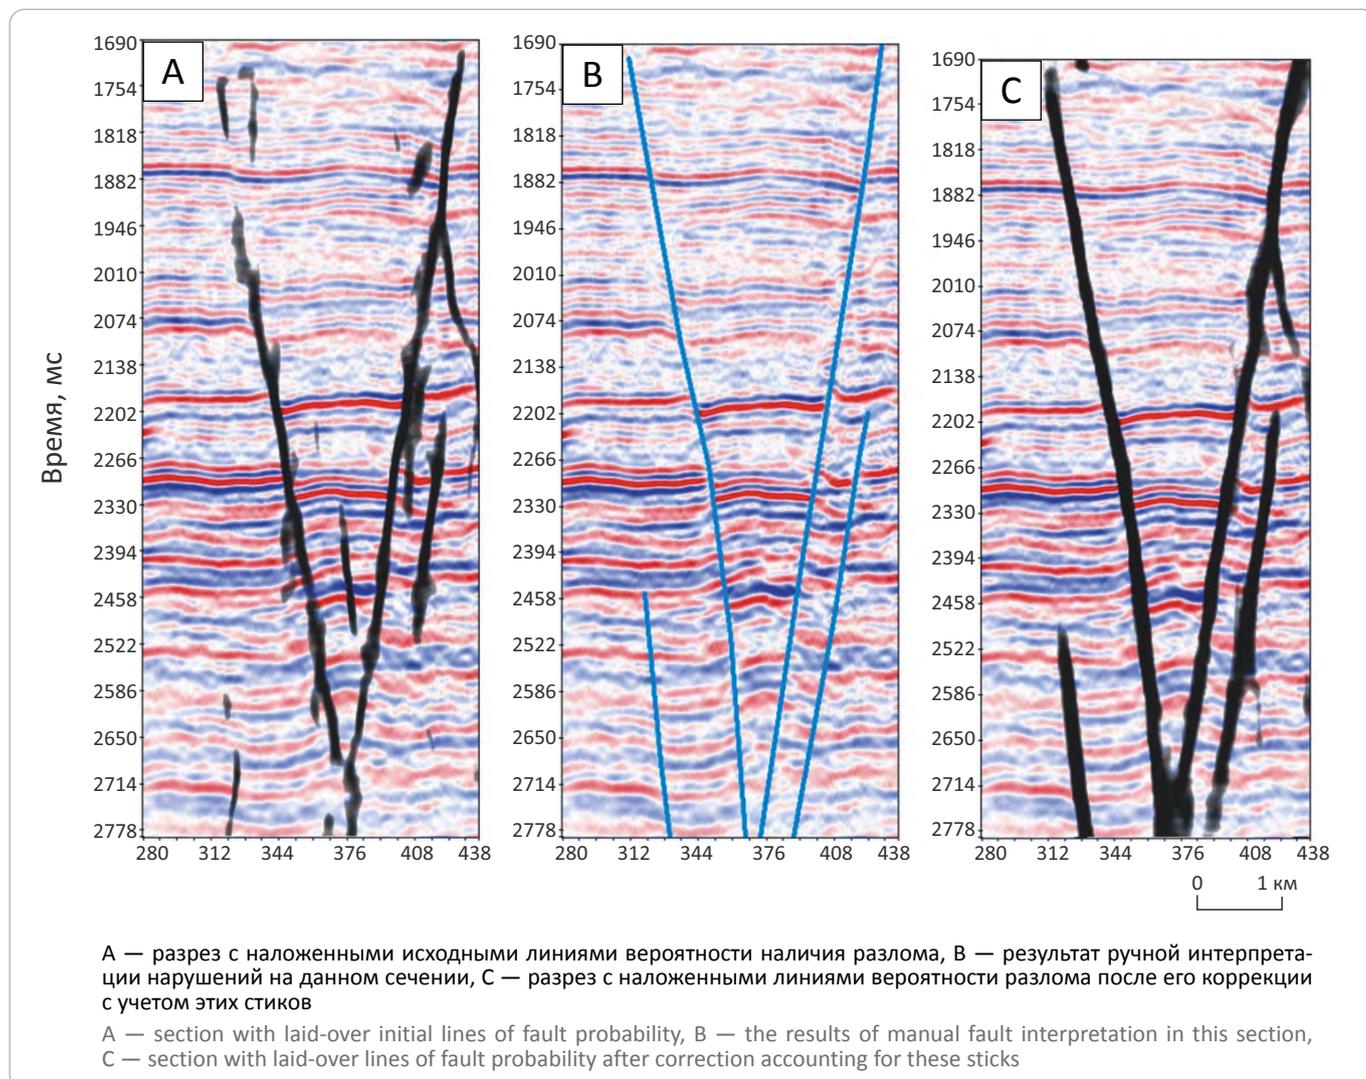
ется на этапе постпроцессинга. Вначале проводится дополнительная фильтрация — очистка куба вероятности для исключения зон ложных срабатываний и сужения линий вероятности для облегчения оценки пространственного положения фрагментов разлома.

На рис. 9 показан пример улучшения атрибута вероятности разлома на 3D-проекте реальных данных, благодаря чему локализованы зоны поля



## METHODOLOGICAL AND TECHNOLOGICAL ISSUES

**Рис. 8.** Дообучение нейронной сети на кубе 3D  
**Fig. 8.** Neural network transfer learning on 3D volume



вероятности, выполнена опция «уточнения» положения зон разломов.

Далее анализируется поле вероятности вблизи каждой точки с высоким значением вероятности присутствия разлома. Определяются возможный азимут и угол наклона вблизи анализируемой точки. Затем происходит объединение точек высокой вероятности в единую плоскость с учетом определяемых угловых параметров. На завершающем этапе применяется серия процедур редактирования, основанных на представлении об ожидаемом поле нарушений. В том числе накладываются ограничения на минимальную площадь разлома, его угол наклона, радиус поиска точек разлома, окно сглаживания. Управление параметрами редактирования позволяет исполнителю быстро настроить автоматизированную процедуру и получить результат, наилучшим образом отвечающий качеству выделения разломов, осуществляемого наиболее опытными интерпретаторами.

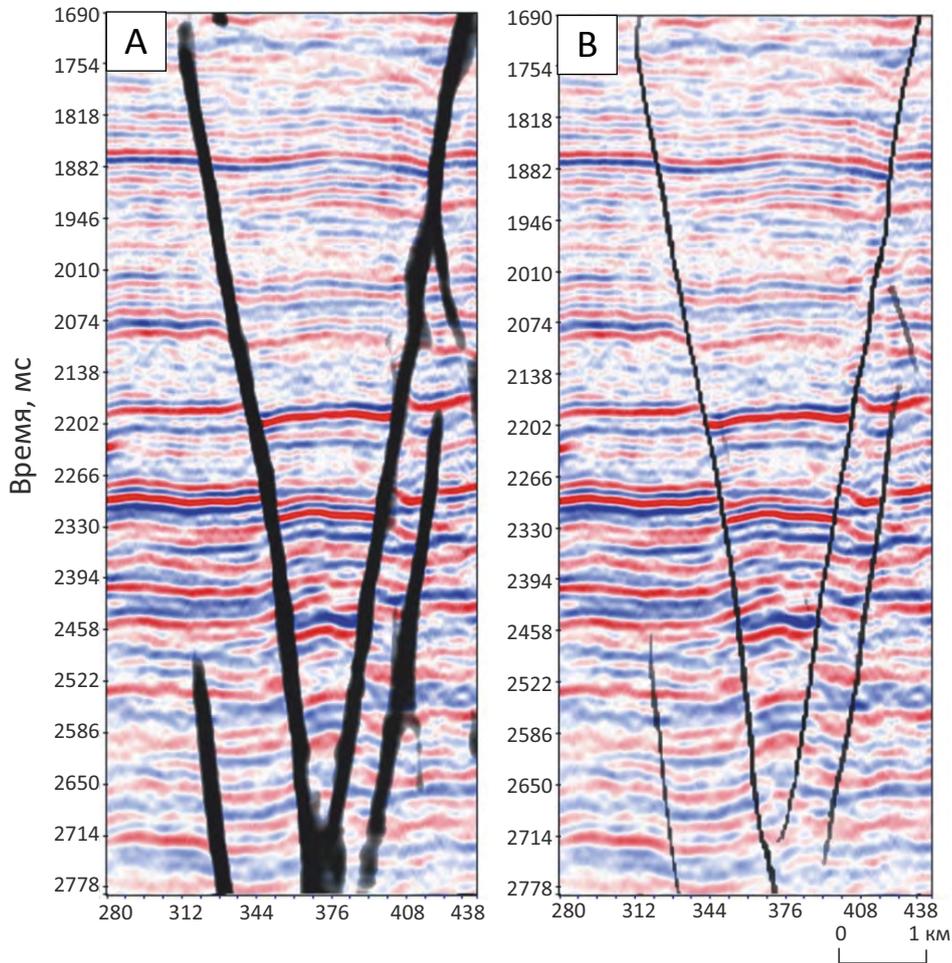
### Примеры применения

На сегодняшний день имеется целая серия практических примеров успешного применения описанного подхода на проектах в районах исследований, существенно различающихся геологическим строением и тектонической обстановкой. Рассмотрим некоторые из них.

Первый пример (рис. 10) относится к районам центральной и северной части Западной Сибири, где на многих разведочных площадях выделены системы кулисных разломов, обусловленные горизонтальными сдвигами в толще палеозойского фундамента [10].

Второй пример (рис. 11) также относится к районам Западной Сибири, но иллюстрирует особенности выделения многочисленных тектонических нарушений в юрских отложениях между кровлей палеозойского фундамента и баженовским горизонтом. Нейронные сети здесь работают как весьма опытный

**Рис. 9.** Постпроцессинг атрибута  
**Fig. 9.** Attribute post-processing



A — разрез с наложенными линиями вероятности наличия разлома до постпроцессинга, B — результат постпроцессинга  
 A — section with laid-over lines of fault existence probability prior to post-processing, B — post-processing result

интерпретатор, реагируя на скачкообразное смещение осей синфазности, резкою смену характера волновой картины, изменение динамики отражений.

Следующий пример иллюстрирует автоматизированное выделение весьма сложной системы тектонических нарушений в отдельных районах шельфа (рис. 12).

Вышеприведенные примеры практически не потребовали дообучения сети, поскольку характеристики нарушений в этих случаях хорошо соответствовали аналитическим образцам, на которых проводилось первичное обучение сети. Другая ситуация имела место на следующем примере из Саратовской области, где тектонические нарушения в явном виде выделяются очень плохо. Они приурочены к флексуобразным перегибам геологических поверхностей. Для того чтобы сеть правильно отреагировала на такого рода нарушения, было выполнено дообу-

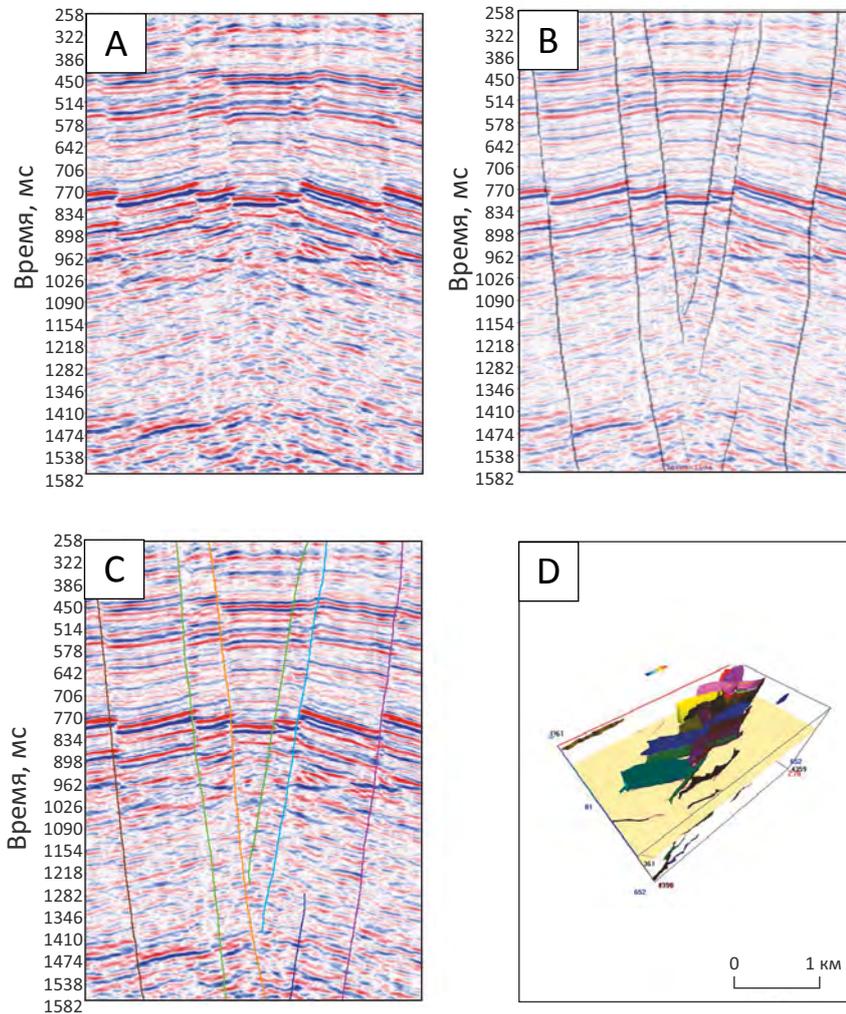
чение сети (рис. 13). Были выделены те нарушения, которые отметил геофизик. На всем кубе также был выделен ряд других нарушений, которые по своим характеристикам соответствовали ранее выделенным геофизиком.

### Заключение

Предложенный вариант использования машинного обучения для решения задач автотрассирования нарушений нивелирует серию ограничений аналитических алгоритмов и обладает комплексом преимуществ, среди которых основными являются: устойчивость к качеству сейсмических данных, упрощение этапа препроцессинга, существенное увеличение скорости расчетов, оптимизация этапа постпроцессинга и получение качественного результата трассирования нарушений при работе с материалом различной степени сложности. Весьма существенно, что первичное обучение сети, занимающее достаточно

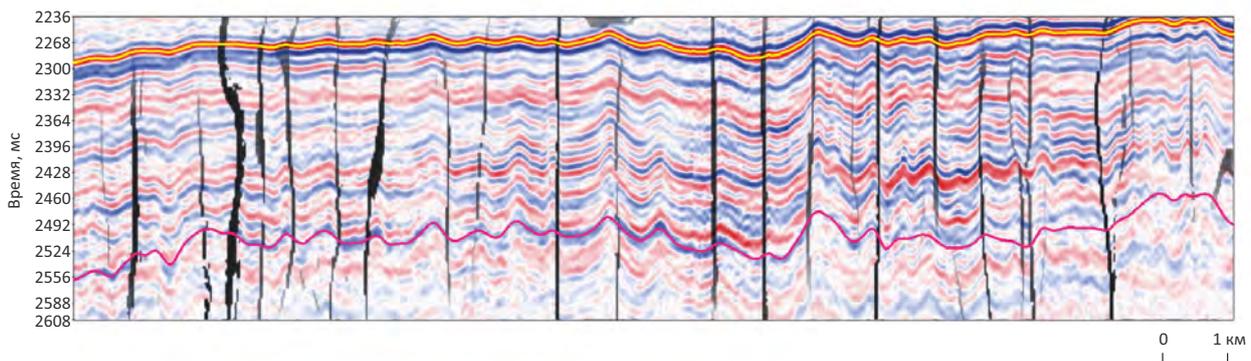
METHODOLOGICAL AND TECHNOLOGICAL ISSUES

**Рис. 10.** Картирование кулисной системы разломов  
**Fig. 10.** Mapping of an echelon fault system

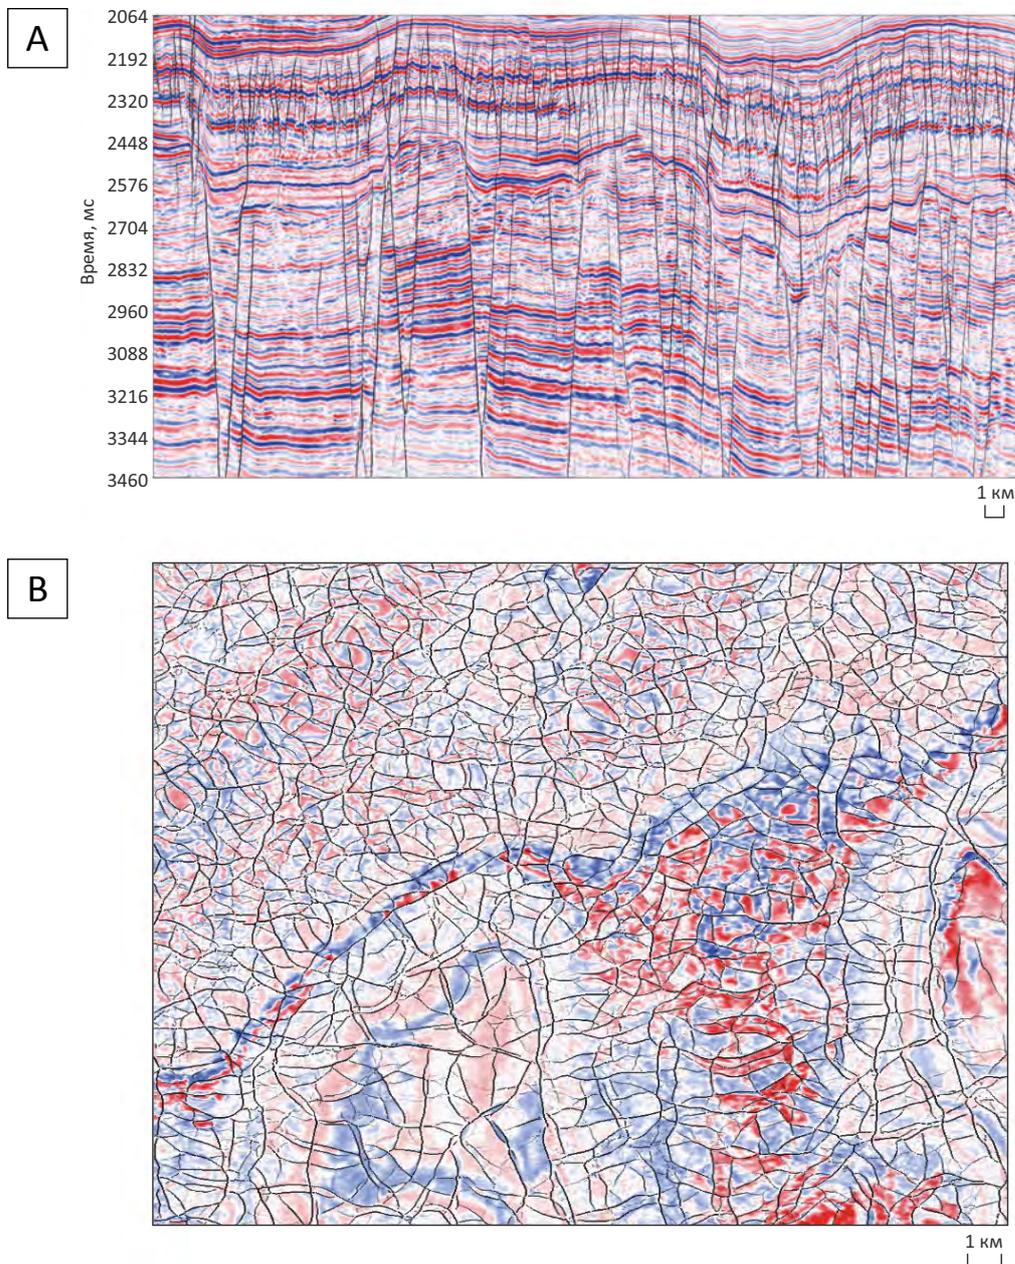


A — сечение куба 3D со сложной системой разломов, B — первичные линии разломов, выделенные обученной нейронной сетью, C — сечения выделенных плоскостей разломов (показаны цветом), D — выделенная система разломов в изометрическом отображении  
 A — 3D volume section with a complicated fault system, B — initial fault lines identified by the trained neural network, C — sections of the identified fault surfaces (in colour), D — isometric view of the selected fault system

**Рис. 11.** Пример выделения многочисленных тектонических нарушений в юрских отложениях Западной Сибири  
**Fig. 11.** An example of numerous faults identification within the Jurassic series of Western Siberia



**Рис. 12.** Автоматизированное выделение сложной системы тектонических нарушений на шельфе (морская сейсморазведка)  
**Fig. 12.** Computer-aided identification of the complicated fault system on shelf (marine seismic survey)



A — фрагмент вертикального сечения куба 3D с выделенной нейронной сетью сложной системой многочисленных нарушений (высокоамплитудные системообразующие разломы, затрагивающие всю толщу разреза, и интервал малоамплитудных густо расположенных полигональных нарушений в верхней части фрагмента сейсмического разреза), B — горизонтальное сечение фрагмента куба 3D в интервале развития малоамплитудных полигональных нарушений  
 A — fragment of 3D volume vertical section with a complicated system of numerous faults identified by neural network (high-amplitude backbone faults affecting the entire package, and an interval of low-amplitude closely spaced polygonal faults in the upper part of the seismic section), B — horizontal section of 3D volume fragment in the interval of low-amplitude polygonal faults occurrence

много машинного времени, выполняется один раз, но, благодаря наличию быстродействующего аппарата дообучения сети, может быть успешно использовано в самых разных геологических условиях при различном характере поля нарушений.

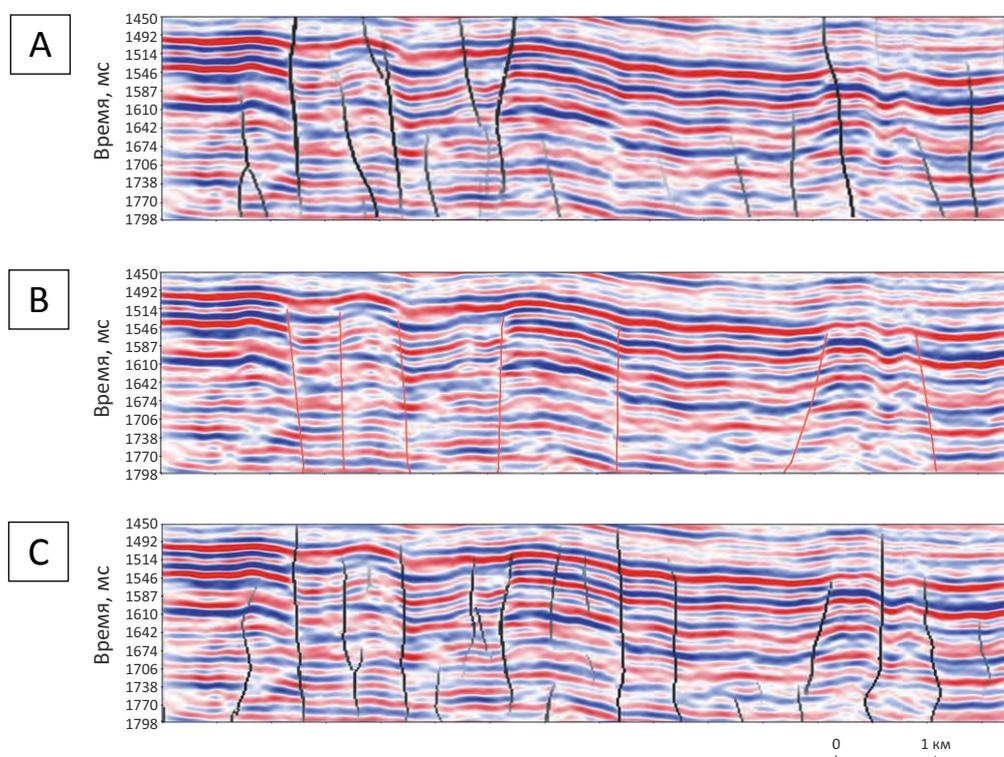
Дополнительная возможность ручной настройки нейронной сети позволяет интерпретатору быстро подобрать такой режим работы сети и выделения нарушений, который наилучшим образом отвечает его представлениям, открывает пути к решению задачи



## METHODOLOGICAL AND TECHNOLOGICAL ISSUES

**Рис. 13.** Пример картирования слабо выделяющихся нарушений на разведочной площади в Саратовской области

**Fig. 13.** An example of mapping of poorly identifiable faults in the exploratory area, the Saratov Region



А — фрагмент сечения куба 3D с первично выделенными вероятными нарушениями при использовании базовой модели, В — дополнительно выделенные геофизиком нарушения, с учетом которых выполнено дообучение сети, С — выделение нарушений после дообучения сети

A — fragment of 3D volume section with probable faults initially identified using a basic model, B — faults additionally identified by geophysicist, which are taken into account in neural network transfer learning, C — faults identification after network transfer learning

автоматизации этапа трассирования разломов высокой степени сложности: надвиги, листрические разломы и т. д.

Представленный в статье ряд практических примеров применения разработанных алгоритмов выделения систем тектонических нарушений дает достаточно наглядное представление о возможностях

нового метода, который, наряду с другими прикладными задачами применения машинного обучения и глубоких нейронных сетей для обработки и интерпретации сейсмических данных, будет положен в основу новых интегрированных систем применения искусственного интеллекта при решении геолого-геофизических задач.

### Литература

1. Barnes A.E. A filter to improve seismic discontinuity data for fault interpretation // *Geophysics*. – 2006. – Т. 71. – № 3. – С. P1–P4. DOI:10.1190/1.2195988.
2. Hale D. Methods to compute fault images, extract fault surfaces, and estimate fault throws from 3d seismic images // *Geophysics*. – 2013. – Т. 78. – № 2. – С. O33–O43. DOI:10.1190/geo2012-0331.1.3. Hall B. Facies classification using machine learning // *The Leading Edge*. – 2016. – Т. 35. – № 10. – С. 906–909. DOI:10.1190/tle35100906.1.
4. Priezzhev I.I., Veeken P.C.H., Egorov S.V., Strecker U. Direct prediction of petrophysical and petroelastic reservoir properties from seismic and well-log data using nonlinear machine learning algorithms // *The Leading Edge* – 2019. – Т. 38. – № 12. – С. 949–960. DOI:10.1190/tle38120949.1.
5. Naeini E.Z., Green S., Russell-Hughes I., Rauch-Davies M. An integrated deep learning solution for petrophysics, pore pressure, and geomechanics property prediction // *The Leading Edge*. – 2019. – Т. 38. – № 1. – С. 53–60. DOI:10.15530/urtec-2019-111.
6. Zhao X., Lu P., Zhang Ya., Chen J., Li X. Swell-noise attenuation: A deep learning approach // *The Leading Edge*. – 2019. – Т. 38. – № 12. – С. 934–942. DOI:10.1190/tle38120934.1.
7. Xiong W., Ji X., Ma Y., Wang Y., AlBenHassan N.M., Ali M.N., Luo Y. Seismic fault detection with convolutional neural network // *Geophysics*. – 2018. – Т. 83. – № 5. – С. O97–O103. DOI:10.1190/geo2017-0666.1.

8. Wu X., Shi Y., Fomel S., Liang L., Zhang Q., Yusifov A. FaultNet3D: Predicting fault probabilities, strikes and dips with a common CNN // IEEE Transactions on Geoscience and Remote Sensing. – 2019. – Т. 57. – №11. – С. 9138–9155. DOI:10.1109/TGRS.2019.2925003.
9. Zheng Y., Zhang Q., Yusifov A., Shi Y. Applications of supervised deep learning for seismic interpretation and inversion // The Leading Edge. – 2019. – Т. 38. – № 7. – С. 526–533. DOI:10.1190/tle38070526.1.
10. Гогоненков Г.Н., Тимурзиев А.И. Сдвиговые деформации в чехле Западно-Сибирской плиты и их роль при разведке и разработке месторождений нефти и газа // Геология и геофизика. – 2010. – Т. 51. – № 3. – С. 384–400.

## References

1. Barnes A.E. A filter to improve seismic discontinuity data for fault interpretation. *Geophysics*. 2006;71(3):P1–P4. DOI:10.1190/1.2195988.
2. Hale D. Methods to compute fault images, extract fault surfaces, and estimate fault throws from 3d seismic images. *Geophysics*. 2013;78(2):O33–O43. DOI:10.1190/geo2012-0331.1.
3. Hall B. Facies classification using machine learning. *The Leading Edge*. 2016;35(10):906–909. DOI:10.1190/tle35100906.1.
4. Priezzhev I.I., Veeken P.C.H., Egorov S.V., Strecker U. Direct prediction of petrophysical and petroelastic reservoir properties from seismic and well-log data using nonlinear machine learning algorithms. *The Leading Edge*. 2019;38(12):949–960. DOI:10.1190/tle38120949.1.
5. Naeini E.Z., Green S., Russell-Hughes I., Rauch-Davies M. An integrated deep learning solution for petrophysics, pore pressure, and geomechanics property prediction. *The Leading Edge*. 2019;38(1):53–60. DOI:10.15530/urtec-2019-111.
6. Zhao X., Lu P., Zhang Ya., Chen J., Li X. Swell-noise attenuation: A deep learning approach. *The Leading Edge*. 2019;38(12):934–942. DOI:10.1190/tle38120934.1.
7. Xiong W., Ji X., Ma Y., Wang Y., AlBenHassan N.M., Ali M.N., Luo Y. Seismic fault detection with convolutional neural network. *Geophysics*. 2018;83(5):O97–O103. DOI:10.1190/geo2017-0666.1.
8. Wu X., Shi Y., Fomel S., Liang L., Zhang Q., Yusifov A. FaultNet3D: Predicting fault probabilities, strikes and dips with a common CNN. *IEEE Transactions on Geoscience and Remote Sensing*. 2019;57(11):9138 – 9155. DOI:10.1109/TGRS.2019.2925003.
9. Zheng Y., Zhang Q., Yusifov A., Shi Y. Applications of supervised deep learning for seismic interpretation and inversion. *The Leading Edge*. 2019;38(7):526–533. DOI:10.1190/tle38070526.1.
10. Gogonenkov G.N., Timurziev A.I. Strike-slip faults in the West Siberian basin: implications for petroleum exploration and development. *Russian Geology and geophysics*. 2010;(3):304–316.

## Информация об авторах

### Мифтахов Руслан Фанисович

Технический директор  
ООО «ГридПоинт Дайнамикс»,  
123423 Москва, ул. Народного Ополчения, д. 34  
e-mail: r.miftakhov@geoplat.com

### Авдеев Павел Алексеевич

Заместитель директора по развитию бизнеса  
ООО «ГридПоинт Дайнамикс»,  
123423 Москва, ул. Народного Ополчения, д. 34  
e-mail: p.avdeev@geoplat.com  
ORCID ID: 0000-0002-5113-8523

### Гогоненков Георгий Николаевич

Доктор технических наук,  
советник генерального директора  
ФГБУ «Всероссийский научно-исследовательский  
геологический нефтяной институт»,  
105118 Москва, ш. Энтузиастов, д. 36  
e-mail: gogonenkov@vnigni.ru  
ORCID ID: 0000-0001-9954-4558

## Information about authors

### Ruslan F. Miftakhov

Chief Technology Officer  
Gridpoint Dynamics,  
34, ul. Narodnogo Opolcheniya, Moscow, 123423, Russia  
e-mail: r.miftakhov@geoplat.com

### Pavel A. Avdeev

Deputy Director of Business Development  
Gridpoint Dynamics,  
34, ul. Narodnogo Opolcheniya, Moscow, 123423, Russia  
e-mail: p.avdeev@geoplat.com  
ORCID ID: 0000-0002-5113-8523

### Georgy N. Gogonenkov

Doctor of technical Sciences,  
Advisor to Director-General  
All-Russian Research  
Geological Oil Institute,  
36, Shosse Entuziastov, Moscow, 105118, Russia  
e-mail: gogonenkov@vnigni.ru  
ORCID ID: 0000-0001-9954-4558

**METHODOLOGICAL AND TECHNOLOGICAL ISSUES****Базанов Андрей Константинович**

Директор по развитию бизнеса  
ООО «ГридПоинт Дайнамикс»,  
123423 Москва, ул. Народного Ополчения, д. 34  
e-mail: a.bazanov@geoplat.com  
ORCID ID: 0000-0002-0159-1661

**Ефремов Игорь Иванович**

Генеральный директор  
ООО «ГридПоинт Дайнамикс»,  
123423 Москва, ул. Народного Ополчения, д. 34  
e-mail: i.efremov@geoplat.com

**Andrei K. Bazanov**

Director of Business Development  
Gridpoint Dynamics,  
34, ul. Narodnogo Opolcheniya, Moscow, 123423, Russia  
e-mail: a.bazanov@geoplat.com  
ORCID ID: 0000-0002-0159-1661

**Igor I. Efremov**

Director General  
Gridpoint Dynamics,  
34, ul. Narodnogo Opolcheniya, Moscow, 123423, Russia  
e-mail: i.efremov@geoplat.com