

(19)



**Евразийское
патентное
ведомство**

(11) **047437**

(13) **B1**

(12) **ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОМУ ПАТЕНТУ**

(45) Дата публикации и выдачи патента
2024.07.22

(21) Номер заявки
202393395

(22) Дата подачи заявки
2023.11.02

(51) Int. Cl. **G01V 1/30** (2006.01)
G06N 3/08 (2023.01)
G06N 3/02 (2006.01)
G01V 99/00 (2024.01)

(54) **ПРОЦЕДУРА ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВЕ ФИЗИЧЕСКОГО
МОДЕЛИРОВАНИЯ ГЕОФИЗИЧЕСКИХ ДАННЫХ**

(43) **2024.07.17**

(96) **2023000180 (RU) 2023.11.02**

(71)(73) Заявитель и патентовладелец:
**ОБЩЕСТВО С ОГРАНИЧЕННОЙ
ОТВЕТСТВЕННОСТЬЮ
"ГРИДПОИНТ ДАЙНАМИКС" (RU)**

(72) Изобретатель:
**Ефремов Игорь Иванович, Мифтахов
Руслан Фанисович, Базанов Андрей
Константинович, Никоненко Юрий
Андреевич, Шевырев Никита
Алексеевич (RU)**

(74) Представитель:
Котлов Д.В. (RU)

(56) US-B2-11698471
US-B1-11768982
WO-A1-2021252932
WO-A1-2022139836
RU-C2-2782505
Wei Dai, Winston Lewis, Kun Jiao, and Richard Coates, Schlumberger, Least-squares Reverse-time Migration with Structure Preconditioning, Conference: SEG Technical Program Expanded Abstracts 2016, September 2016, онлайн [найдено 18.03.2024] в <https://www.researchgate.net/publication/307880467_Least-squares_reverse_time_migration_with_structure_preconditioning> Весь документ
Yu Zhang, Lian Duan, Yi Xie, A stable and practical implementation of least-squares reverse time migration, Manuscript received by the Editor 11 December 2013; revised manuscript received 13 August 2014; published online 22 December 2014, онлайн [найдено 18.03.2024] в <<https://www.cgg.com/resources/technical-content/industry-article/stable-and-practical-implementation-least-squares>>Весь документ

(57) Изобретение относится к области вычислительной техники, в частности, описывается метод предварительного обучения нейронной сети на большом объеме синтетических данных и дальнейшее применение этой сети к реальным сейсмическим данным.

B1

047437

**047437
B1**

Область техники

Настоящее изобретение относится к области вычислительной техники, в частности, к способу обучения нейронных сетей на основе физического моделирования геофизических данных.

Уровень техники

Из уровня техники известно изобретение, выбранное в качестве наиболее близкого аналога, US 2019064389 (A1), опублик. 28.02.2019. Данное изобретение характеризует способ, который включает в себя этапы: сохранение в памяти компьютера геофизических данных, полученных в результате исследования участка недр; и извлечение с помощью компьютера модели физических свойств недр путем обработки геофизических данных с помощью одной или нескольких сверточных нейронных сетей, которые обучены связывать геофизические данные по меньшей мере с одним физическим свойством недр, согласующимся с предварительной геологической информацией.

Предлагаемое изобретение направлено на устранение недостатков современного уровня техники и отличается от известных ранее тем, что предложенное изобретение обеспечивает качественное и эффективное использование физического моделирования геофизических данных для целей машинного обучения, что включает, но не ограничивается, нахождением разломов.

Сущность изобретения

Технической проблемой, на решение которой направлено заявленное изобретение, является создание способа обучения нейронных сетей на основе физического моделирования геофизических данных.

Ключевым техническим результатом данного изобретения является повышение точности и надежности прогнозов и интерпретаций геофизических данных. Физическое моделирование позволяет взаимодействовать с данными более глубоко и учитывать сложные взаимодействия между различными параметрами. Это дает возможность улучшить прогнозирование в сложные геологические условия, а также более точно интерпретировать результаты измерений и наблюдений.

Заявленный технический результат достигается за счет осуществления способа обучения нейронных сетей на основе физического моделирования геофизических данных, включающего этапы, на которых:

осуществляется генерация модели отражающих границ, а также формируется разметка разломной тектоники, за счет создания двухмерных или трехмерных отражающих моделей;

осуществляется создание модели интервальных скоростей между отражающими границами, за счет формирования базовой скоростной модели и применения скоростных изменений, соответствующих структуре отражающей модели;

осуществляется подготовка данных для процедуры миграции с целью получения мигрированной сейсмики, за счет создания сглаженных моделей интервальных скоростей, полученных на предыдущем этапе, при этом сглаженные модели используются в качестве входных данных для миграции и являются начальными скоростными моделями, которые уточняются посредством процедуры миграции;

осуществляется миграция моделей и получение мигрированной сейсмики на котором скоростные модели, сформированные на предыдущем этапе, подвергаются миграции посредством алгоритмов LSRTM (Least-Squares Reverse Time Migration), а именно итерационный процесс LSRTM начинается с прямого моделирования начальной модели скоростей, полученной на предыдущем этапе, с учетом геометрии источников и приёмников, после чего следует обратная во времени миграция моделированных данных, далее полученные данные сравниваются с данными, полученными на предыдущем этапе прямым моделированием на моделях скоростей до сглаживания, а разница между ними определяет обновление скоростной модели, причем процесс повторяется в течение нескольких итераций, каждая из которых улучшает точность скоростной модели и качество мигрированных данных.

В частном варианте реализации описываемого изобретения, на этапе подготовки данных для процедуры миграции, в качестве априорных данных для миграции используются сейсмограммы, полученные прямым моделированием до процедуры сглаживания.

В другом частном варианте реализации описываемого изобретения, на этапе подготовки данных для процедуры миграции для сглаживания используется Гауссова фильтрация.

В другом частном варианте реализации описываемого изобретения, на этапе подготовки данных для процедуры миграции осуществляется подготовка сглаженных скоростных моделей для миграции, а именно задается сетка приёмников и источников на поверхности сглаженных скоростных моделей для последующих решений уравнения продольной волны для заданной модели среды внутри алгоритма миграции в обратном времени.

В другом частном варианте реализации описываемого изобретения на вход нейронная сеть принимает массивы сейсмических данных, полученных в ходе миграционного процесса, и информацию о разломах, сформированную на начальном этапе.

Описание чертежей

Реализация изобретения будет описана в дальнейшем в соответствии с прилагаемыми чертежами, которые представлены для пояснения сути изобретения и никоим образом не ограничивают область изобретения.

К изобретению прилагаются следующие фигуры:

фиг. 1 иллюстрирует примеры, случайным образом, сгенерированных модельных фрагментов сейс-

мической записи с тектоническими нарушениями (верхний ряд без интерпретации, нижний ряд - с наложением заданных тектонических нарушений);

фиг. 2 иллюстрирует процесс моделирования синтетических сейсмических данных;

фиг. 3 иллюстрирует данные отражений;

фиг. 4 иллюстрирует принципиальную схему создания синтетической 3D сеймики;

фиг. 5 иллюстрирует генерацию модели отражающих границ;

фиг. 6 иллюстрирует процесс преобразования отражающей модели в скоростную;

фиг. 7 иллюстрирует пример равномерно распределенной стеки ресиверов и источников для 2D задачи (левый) и 3D (правый) соответственно;

фиг. 8 иллюстрирует последовательность основных этапов при обработке методом LSRTM;

фиг. 9 иллюстрирует принципиальную схему работы миграционного алгоритма;

фиг. 10 иллюстрирует принципиальную схему обучения нейронной сети;

фиг. 11 иллюстрирует результаты прогноза.

Детальное описание изобретения

В приведенном ниже подробном описании реализации изобретения приведены многочисленные детали реализации, призванные обеспечить отчетливое понимание настоящего изобретения. Однако, квалифицированному в предметной области специалисту, будет очевидно каким образом можно использовать настоящее изобретение, как с данными деталями реализации, так и без них. В других случаях хорошо известные методы, процедуры и компоненты не были описаны подробно, чтобы не затруднять излишне понимание особенностей настоящего изобретения.

Кроме того, из приведенного изложения будет ясно, что изобретение не ограничивается приведенной реализацией. Многочисленные возможные модификации, изменения, вариации и замены, сохраняющие суть и форму настоящего изобретения, будут очевидными для квалифицированных в предметной области специалистов.

В последние годы машинное обучение и нейронные сети стали широко использоваться в геофизических исследованиях для анализа, интерпретации и классификации геофизических данных. Однако, для успешного обучения нейросетей требуется большое количество обучающих данных, которые часто сложно получить на практике. В связи с этим возникает потребность в создании синтетических данных, которые могут быть использованы для обучения моделей машинного обучения.

Осознавая центральную роль сейсмической информации в изучении природных ресурсов и планировании их разработки, мы сталкиваемся со сложностями при анализе и интерпретации этих данных из-за их объема, сложности и неопределенности.

С течением времени машинное обучение и искусственный интеллект оказались ценными инструментами в геофизике, облегчая автоматический и точный анализ больших объемов данных. Среди различных методологий, физическое моделирование геофизических данных становится важным подходом, предлагающим уникальные преимущества при обучении нейронных сетей.

В настоящем изобретении мы используем физическое моделирование для генерации синтетических данных, которые отражают ключевые геофизические процессы и структуры. Этот подход упрощает исходные данные, что улучшает процесс обучения, при этом сохраняет достаточную сложность для обучения эффективных моделей на примере тектонических нарушений.

Мы описываем метод предварительного обучения нейронной сети на большом объеме синтетических данных, а затем применения этой сети к реальным сейсмическим данным. Этот процесс включает в себя разработку большой коллекции трехмерных моделей для обучения, что существенно упрощает и улучшает выделение разломов на реальных данных. Отказ от использования реальных данных на этапе предварительного обучения нейронной сети обусловлен целой серией факторов: необходимостью качественного предварительного ручной интерпретации на каждом наборе данных, ограниченностью набора доступных открытых данных и, в особенности, невозможностью однозначной верификации результата предсказания зон разломов ввиду неоднозначности ручного выделения, которая характерна для большого количества 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.

Описанный подход обеспечивает значительное улучшение в выделении разломов в сейсмических данных, что делает его важным инструментом для любого специалиста в области геофизики, который использует машинное обучение в своей работе.

Генерация синтетических геофизических данных.

В контексте машинного обучения для обработки и анализа геофизических данных, первый критический этап - это генерация большого объема модельных сегментов сейсмического волнового поля для

обучения выбранной нейронной сети. Каждый из этих сегментов представляет собой набор квазипараллельных отражающих границ, которые нарушены одним или несколькими разломами.

В целях обучения сети наиболее эффективно, генерируются тысячи, а то и десятки тысяч, элементарных сегментов 3D с произвольным набором отражающих границ и нарушений. Эти нарушения могут проходить под любыми азимутами и с заданным диапазоном углов наклона. На фиг. 1 приведены примеры модельных сегментов, используемых для обучения нейронной сети. Верхний ряд представляет собой модельные сегменты без интерпретации, тогда как нижний ряд отображает те же модели с выделенными тектоническими нарушениями.

Благодаря использованию тысяч, таких, случайно сгенерированных, сегментов, создается обучающий набор данных, который может быть усложнен путем наложения случайного шума или регулярных помех.

Процесс моделирования синтетических сейсмических данных включает данные отражений (301), добавление структурного шума (302), указание расположения складок, разломов и зон несогласия (303), а также изменения амплитуды разломов (304). В процессе также проводится моделирование затухающего смещения разлома (305) и микроразрывов (306).

Затем эти модели сворачиваются с Рикеровым вейвлетом - типичным вейвлетом, используемым в сейсмике, чтобы преобразовать отражающие модели в синтетические сейсмические данные. Этот процесс помогает в создании реалистичных сейсмических откликов.

Процесс создания 3D синтетических данных в нашем генераторе для целей сегментации разломов включает следующие ключевые этапы:

1. Инициализация параметров модели: определяются основные параметры модели, такие как размеры NX, NY и NZ, а также другие характеристики, которые отражают специфическую геологическую структуру.

2. Создание модели отражений: на основе инициализированных параметров создается 3D модель отражений, которая представляет собой представление подземных структур.

3. Задание расположения складок: в данном шаге определяются позиции и ориентация складок внутри модели, что отражает сложные геологические паттерны.

4. Задание вейвлета: для преобразования модели отражений в синтетические сейсмические данные необходимо определить вейвлет, который будет использован для свертки с моделью отражений.

5. Свертка модели отражений с вейвлетом: Модель отражений сворачивается с выбранным вейвлетом, что приводит к созданию синтетических сейсмических данных, отражающих реалистичные сейсмические отклики.

6. Задание разломов: в этом этапе в модель добавляются разломы, которые представляют собой важные геологические структуры.

7. Добавление шума (опционально): в соответствии с требованиями задачи, можно добавить шум к синтетическим сейсмическим данным для имитации реальных условий и увеличения устойчивости модели.

На выходе мы получаем два основных продукта: синтетическую 3D сейсмiku и соответствующую ей 3D сегментацию разломов, представляющую собой массив данных аналогичного размера исходной сейсмiku, содержащий разметку расположения разломов в пространстве.

Несмотря на преимущества представленного процесса моделирования данных, он не лишен ряда проблем и сложностей. Существуют фундаментальные вызовы, связанные с качеством и объемом имеющихся геофизических данных, вариативностью геологических структур, а также сложностями, связанными с моделированием шумов и артефактов как на реальных данных.

Физическое моделирование геофизических данных может стать решением этих проблем. Оно позволяет генерировать синтетические, но в то же время реалистичные данные, которые с большой точностью отображают сложные подземные структуры. Это, в свою очередь, облегчает процесс обучения нейронных сетей, которые должны анализировать и интерпретировать эти данные. Благодаря использованию такого подхода, обученные модели будут более надежными и точными, улучшая качество прогнозирования геофизических параметров и интерпретации геологических структур.

Физическое моделирование геофизических данных включает создание моделей напластования и симуляцию сейсмических волн, проходящих через эти модели. Это позволяет создавать синтетические сейсмограммы, которые отражают приближенные к реальным геологическим условиям.

Теория и принципы физического моделирования геофизических данных.

Основопологающей целью физического моделирования является генерация синтетических данных, которые максимально точно воспроизводят реальные геофизические процессы.

Особенностью работы с синтетическими данными, полученными в предыдущей главе, является их потенциал для дальнейшего совершенствования и насыщения. Одним из способов дополнительного обогащения этих данных является использование методов миграции, которые добавляют в них больше "физики". Подобные методы используют уравнения волнового поля для моделирования распространения акустических волн в геологических структурах. Это позволяет не просто смоделировать синтетическую картину геологического строения, но и воссоздать ее волновые характеристики, которые являются клю-

чевыми для анализа и интерпретации сейсмических данных.

В контексте геофизического моделирования существует ряд методов миграции, каждый из которых имеет свои преимущества и ограничения. Так, классический метод Кирхгофа характеризуется простотой и легкостью реализации, но имеет ограниченную точность при моделировании сложных геологических структур. Фазовая миграция, с другой стороны, обеспечивает более высокую точность, но требует большой вычислительной мощности и сложного алгоритма. В то время как алгоритмы волновой миграции, такие как Reverse Time Migration (RTM), предлагают наилучшее качество изображения для более сложных геологических структур. Однако все эти методы страдают от недостатков, связанных с неоднозначностью и ошибками при восстановлении скоростных моделей.

Мы выбрали метод Least Squares Reverse Time Migration (LSRTM) для нашего исследования, так как он учитывает все вышеперечисленные аспекты, предлагая при этом значительные преимущества. LSRTM не только улучшает качество изображения, но и компенсирует несовершенства синтетической скоростной модели, применяя метод наименьших квадратов для минимизации разницы между отраженной смоделированной волной для сглаженной скоростной модели среды и смоделированной волной для истинной скоростной модели. Это повышает точность итоговой отражающей модели и делает LSRTM идеальным инструментом для наших целей - создания реалистичных синтетических геофизических данных для машинного обучения.

Далее мы подробно рассмотрим процесс генерации моделей набора отражающих границ, трансформацию в скоростную модель, её последующую миграцию и получение итоговой мигрированной сейсмике.

Описание разработанного процесса моделирования.

В этой части подробно рассмотрим разработанный процесс моделирования, который позволяет генерировать синтетические сейсмические данные, отражающие реалистичную геологическую структуру. Моделирование выполняется в четыре этапа: создание модели отражающих границ, её преобразование в модель интервальных скоростей между отражающими границами, подготовка моделей к миграции и итоговая миграция модели скоростей с использованием её сглаженной версии.

Каждый из этих этапов имеет свою специфику и важность для получения реалистичных сейсмических данных. Они сочетают в себе глубокое понимание геологических процессов и применение передовых алгоритмов и техник моделирования. Вместе они позволяют создавать обучающие данные, которые с большей точностью отражают сложные структуры и физические процессы, происходящие в них.

Генерация модели отражающих границ.

Первый этап процесса моделирования является важным звеном между реальной геологической средой и её математической аппроксимацией.

Отражающие модели представляют подземные структуры, включая такие особенности как разломы, аномалии и сложные геоструктурные паттерны. Они являются точной математической репрезентацией предполагаемого распределения геологических образований в подземном пространстве.

Основное значение этого этапа заключается в том, что именно эти модели используются как основа для создания синтетических сейсмических данных. Они выступают как "истина на земле", относительно которой синтетические данные могут быть проверены и с которой они должны быть в согласии. Этот этап является ключевым, потому что точность отражающих моделей напрямую влияет на реалистичность последующих синтетических данных.

Процесс создания этих моделей, включающий свертку с Рикеровым вейвлетом для преобразования отражающих моделей в синтетические сейсмические данные, идентичен тому, что было описано ранее.

Создание модели интервальных скоростей между отражающими границами.

Второй этап представляет собой критически важный момент в процессе моделирования, когда отражающие модели из первого этапа преобразуются в скоростные модели. Этот этап подчеркивает необходимость глубокого понимания геофизических процессов, которые отражают звуковые волны в земной коре.

Процесс начинается с формирования базовой скоростной модели, которая обычно предполагает градиент скорости, меняющийся в зависимости от глубины. Это первичное предположение может быть уточнено или модифицировано на основе известной геологической информации, такой как данные о скорости в близлежащих скважинах или данные измерений поверхностных волн.

Следующим шагом является применение скоростных изменений, соответствующих структуре отражающей модели. Эти изменения могут быть основаны на различных физических параметрах, таких как изменения плотности или пористости, которые в свою очередь влияют на скорость распространения звука.

Итоговая формула преобразования модели отражающих границ, полученной на первом этапе в модель интервальных скоростей между отражающими границами, выглядит следующим образом:

$$\vartheta(x, y, z_i) = \vartheta_{min} + \alpha_{per} * R(x, y, z) * 1 \frac{m}{s} + \Delta z * z_i * P * \frac{1}{s},$$

где $\vartheta(z)$ [м/с] - итоговая модель отражающих границ;

ϑ_{\min} , число [м/с] - минимальная скорость для данной модели среды;
 α_{per} , число - глубина "влияния" модели отражений из первого этапа, этот параметр регулирует силу скоростных пертурбаций;
 R , массив данных - модель отражающих границ, полученная на первом этапе;
 Δz , число [м] - расстояние между узлами сетки по оси z ;
 z_i , число - номер слоя массива данных по глубине, $\Delta z \times z_i$ таким образом соответствует глубине i -ого слоя в метрах.

P , число - сила градиента по глубине z , регулирует верхнюю границу скоростей для данной модели.

Ключевое значение этого этапа состоит в том, что скоростные модели являются основой для миграции сейсмических данных. Качество и точность скоростной модели напрямую влияют на качество окончательного сейсмического изображения. Благодаря тщательной работе на этом этапе, можно обеспечить большую точность и реалистичность получаемых сейсмических изображений, что в конечном итоге способствует достижению цели - обучению нейронной сети на точных и реалистичных данных.

Подготовка к миграции.

На этом этапе осуществляется подготовка данных для процедуры миграции с целью получения мигрированной сеймики, минуя этап свёртки с Рикер-вейвлетом. Мы создаём сглаженные модели интервальных скоростей, полученных на втором этапе. Эти модели мы используем в качестве входных данных для миграции - начальные скоростные модели, которые "мы пытаемся уточнить" с помощью процедуры миграции. Для сглаживания подойдёт простая Гауссова фильтрация. В качестве априорных данных для миграции мы используем сейсмограммы, полученные прямым моделированием на "истинных моделях скоростей" - моделях до процедуры сглаживания.

Далее мы подготавливаем сглаженные скоростные модели для миграции. Нам необходимо задать сетку приёмников и источников на поверхности сглаженных скоростных моделей для последующих решений уравнения продольной волны для заданной модели среды внутри алгоритма Миграции в обратном времени. Мы задаем количество источников и ресиверов вдоль оси Y и константную глубину расположения. Равномерное расположение источников в приповерхностных слоях помогает в эффективном использовании алгоритмов Миграции в обратном времени, уменьшая численную дисперсию. При этом равномерное распределение приёмников в моделируемой системе позволяет зафиксировать отклик достаточный для получения корректного результата моделирования геологической среды.

Весь этап разработки скоростной модели является итеративным процессом, в котором геологическая информация постоянно пересматривается и обновляется для улучшения точности и качества модели.

Миграция моделей и получение мигрированной сеймики.

Следующий этап является основой для процедуры, в которой скоростные модели, сформированные на предыдущем этапе, подвергаются миграции с помощью алгоритмов LSRTM (Least-Squares Reverse Time Migration). Этот процесс позволяет трансформировать синтетические модели среды в более детализированные и информативные сейсмические изображения по сравнению со стандартными свёрточными процедурами моделей отражения с вейвлетами. Reverse Time Migration и Least Squares Reverse Time Migration - это методы миграции, используемые в сейсмической обработке для преобразования сейсмических данных из пространства времени в пространство глубины. Они основаны на итеративном решении уравнения волнового поля, которое описывает распространение звуковых волн через горные породы и различные другие типы геологических сред. Алгоритм миграции RTM является одним из наиболее распространённых методов миграции в сейсмической индустрии. Он основан на итеративном решении уравнения волнового поля, которое описывает распространение звуковых волн через горные породы и другие типы геологических сред. На выходе получается "физически оправданный" 3D образ геологической среды.

Least Squares RTM (LSRTM) - это разновидность RTM, использующая метод наименьших квадратов для максимизации сходства между отраженной волной и зеркально отображенной волной в процессе обратной свертки. Использование LSRTM позволяет создать более точные модели, чем RTM, особенно в условиях сложной геологии. Это происходит за счёт учета невязки между моделируемыми данными и данными, полученными в ходе миграции, в процессе обновления скоростной модели на каждой итерации.

При использовании LSRTM происходит не только миграция данных в обратном времени, но и решение обратной задачи кинематики волн. Это позволяет учесть неидеальности модели, которые приводят к возникновению дифракционных и интерференционных эффектов в мигрированных данных.

Миграция позволяет использовать данные о скорости звуковых волн, проникающих через разные слои подземных формаций, и воспроизводит их в обратном порядке от сейсмических детекторов к источникам. Это ведет к восстановлению точного положения и геометрии геологических структур, что существенно улучшает качество интерпретации сейсмических данных.

Значимость этого этапа проста: качество полученных сейсмических изображений напрямую влияет на успешность следующих этапов, включая обучение искусственного интеллекта.

При миграции происходит итерационная процедура, во время которой данные постепенно согласовываются с исходными, что позволяет повысить точность скоростной модели и качество сейсмических

изображений. Этот процесс учитывает различные факторы, такие как амплитуда волны, скоростные аномалии и т.д.

Итерационный процесс LSRTM начинается с прямого моделирования начальной модели скоростей, полученной на предыдущем этапе, с учётом геометрии источников и приёмников. Затем следует обратная во времени миграция моделированных данных. Полученные данные сравниваются с "истинными" данными, полученными на предыдущем этапе прямым моделированием на моделях скоростей до сглаживания. Разница между ними определяет обновление скоростной модели. Этот процесс повторяется в течение нескольких итераций, каждая из которых улучшает точность скоростной модели и качество мигрированных данных. В результате, на выходе алгоритма, мы получаем мигрированную сейсмику, соответствующую нашей "истинной" скоростной модели.

Более подробно этот процесс можно описать следующим образом. Истинная модель отражений и соответствующая ей модель скоростей (m^{true}) и сглаженная скоростная модель (c_0), полученная на предыдущем этапе, являются входными данными для расчета синтетических данных с использованием оператора Борна. Синтетические данные, полученные в этом процессе, рассматриваются как наблюдаемые данные (d^{obs}) в уравнении. (1). Следующим шагом является выбор исходной модели (m_0), используемой для вычисления расчетных данных (d^{calc}). Остаточная ошибка (e_k) представляет собой разницу между расчетными и наблюдаемыми данными.

$$e_k = [d^{calc} - d^{obs}] \quad (1)$$

Ошибка в уравнении (1) обновляется на каждой LSRTM итерации. Для обновления отражающей модели до k+1 состояния оператор миграции G^T применяется к ошибке e_k , чтобы вычислить коррекцию мигрированного изображения g_k (он же градиент), так что,

$$g_k = G^T e_k \quad (2)$$

Используя рассчитанный градиент для итерации k, отражающая модель для следующей итерации рассчитывается по уравнению 3

$$m_{k+1} = m_k - \alpha_k g_k \quad (3)$$

где параметр α_k - длина шага. Для расчета длины шага на первой итерации LSRTM используется максимальное значение градиента. Для последующих используется формула, предложенная Барзилаем Борвейном.

$$\alpha_k^{BB1} = \frac{s_{k-1}^T s_{k-1}}{s_{k-1}^T y_{k-1}} \quad (4)$$

$$\text{где } s_{k-1} = m_k - m_{k-1} \text{ и } y_{k-1} = g_k - g_{k-1}.$$

Вторая формула соответственно:

$$\alpha_k^{BB2} = \frac{s_{k-1}^T y_{k-1}}{y_{k-1}^T y_{k-1}} \quad (5)$$

$$\alpha_k = \left\{ \alpha_k^{BB1}, \text{ if } 0 < \frac{\alpha_k^{BB2}}{\alpha_k^{BB1}} < 1 \right. \left. \alpha_k^{BB2}, \text{ else} \right. \quad (6)$$

На последнем шаге каждой итерации текущая модель m_k обновляется моделью из итерации k+1.

Коротко последовательность действий метода LSRTM изображены на блок-схеме - фиг. 8 и могут быть описаны следующим образом:

1. Вычисление наблюдаемых данных (d^{obs}) из сглаженного поля скоростей (c_0) и отражающей модели (m^{true}) с использованием оператора моделирования Борна;
2. Исходная отражающая модель (m_k) инициализируется сеткой нулей или принимает значение шага 8;
3. Моделирование расчетных данных (d^{calc}) из исходной модели;
4. Вычисление остаточной ошибки (e_k) между расчетными (d^{calc}) и наблюдаемыми данными (d^{obs});
5. Миграция ошибки с использованием оператора RTM;
6. Расчет градиента (g_k);
7. Расчет длины шага для каждой итерации (α_k);
8. Текущее обновление модели ($m_k \rightarrow m_{k+1}$);
9. Повторение процесса для произвольного числа итераций до получения желаемого уровня (диапазон значений) ошибки.

Таким образом, при помощи миграционного алгоритма, происходит миграция моделированных данных в обратном времени. Полученные данные сравниваются с исходными данными, и на основе различий между ними обновляется скоростная модель.

Этот процесс повторяется несколько раз, при каждой итерации улучшая точность скоростной модели и соответственно, качество мигрированных данных. В частном варианте реализации описываемого изобретения, процесс повторяется в диапазоне от 2 до 10 итераций. Хорошее разрешение изображения

геологической среды помогает снизить неопределенность, что дает возможность правильно интерпретировать породы-коллекторы, обнаруживая возможное скопление нефти, газа и других геологических структур. Повышение разрешения изображений становится особенно важным для обнаружения мелко-масштабных геологических особенностей, контролирующих эффективность добычи. Кроме того, метод LSRTM играет важную роль в ослаблении артефактов миграции таких как шум обратного рассеяния, помогая более точно определять границы пород с разной отражающей способностью, улучшить пространственное разрешение и согласовать диапазон амплитуд отражений. Таким образом, использование LSRTM позволяет улучшить качество интерпретации данных и добиться большей точности в определении различных геологических структур и свойств подземных образований.

Мигрированная сеймика приобретает большую реалистичность благодаря интеграции физических принципов в процесс генерации данных, основанного на решении акустических уравнений распространения волн в геологической среде. Это приводит к тому, что получаемое изображение характеризуется большей динамической неоднородностью и повышенным разрешением. Присутствует естественное затухание с глубиной, что делает верхние отражения более выраженными. Вместе с тем, наблюдаются и артефакты, порождаемые процессом миграции, что проявляется в форме нерегулярных шумов вдоль границ модели.

Применение физических синтетических данных для обучения нейросетей.

Данный подход включает в себя ряд важных шагов. Первичный этап начинается с создания моделей отражательности и соответствующих скоростных моделей геологического окружения. Исходя из этих моделей, генерируются наборы базовых синтетических (1) и мигрированных синтетических (2) данных, включающих информацию о геологических разломах. Затем мы применяем эти данные для обучения глубокой сверточной нейронной сети, которая способна проанализировать и интерпретировать структурные аномалии в геологическом контексте, включая разломы. Принципиальная схема обучения нейронной сети показана на фиг. 10.

Нейронная сеть принимает на вход массивы сейсмических данных, полученных в ходе миграционного процесса, и информацию о разломах, сформированную на начальном этапе.

В приведенной схеме изображен процесс обучения нейронной сети. В начале происходит генерация отражающих моделей, то есть моделей, которые прошли весь путь формирования базовых синтетических данных. Параллельно на этапе формируется разметка разломной тектоники - данные, на которых будет обучаться нейронная сеть.

На втором этапе процесс раздваивается: одна часть данных обрабатывается с использованием стандартного вейвлета, в то время как другая проходит через стадии формирования скоростной модели и последующей миграции.

Третий этап - это обучение на базовых синтетических данных и мигрированных синтетических данных. Стоит отметить, что для 2D-случая нейронная сеть обучается на полном объеме мигрированных данных. Однако в 3D мы комбинируем базовые синтетические и мигрированные данные, так как процесс миграции для 3D может занимать значительное время и ресурсы.

В зависимости от размеров моделируемого данных, процесс миграции может занять до 8 ч. Это обуславливает необходимость смешивания данных в 3D-случае для оптимизации процесса обучения нейронной сети.

В итоге, мы получаем обученную нейронную сеть, которая способна анализировать сейсмические данные и автоматически определять разломы. Благодаря своей способности учитывать шумы миграции, дифракционные и волновые артефакты, эта нейронная сеть может значительно улучшить точность и стабильность интерпретации разломов на сейсмических данных.

Применение и результаты.

Результаты прогноза, полученные при помощи миграции, демонстрируют большую протяженность и целостность структурных образований. Они не только совпадают с уже имеющимися предиктивными данными, но также дополняют изображение разломами в местах, которые были неочевидны для интерпретатора, предоставившего нам исходную разметку. Это особенно заметно в верхней и нижней частях изображения, где уровень шумов обычно выше.

Таким образом, применение миграции улучшает общую четкость и точность интерпретации геологических данных, позволяя выявить и детально описать структурные нарушения даже в сложных и зашумленных областях.

В заключение, физическое моделирование геофизических данных выступает мощным инструментом для эффективного обучения машинных моделей, особенно в контексте выявления и интерпретации геологических разломов. Благодаря современным алгоритмам, таким как Reverse Time Migration (RTM) и Least Squares Reverse Time Migration (LSRTM), мы можем создавать реалистичные, детализированные и динамичные модели данных, способные усилить обучающий потенциал синтетических датасетов. Это позволяет машинным моделям эффективно обучаться на основе структурных особенностей и сложностей, которые реалистично отражают реальные геофизические процессы. Такая практика открывает новые возможности для усовершенствования интерпретации геофизических данных, усиливая точность и надежность прогнозов и интерпретаций. Итогом данного процесса становится формирование эффектив-

ных и мощных инструментов для анализа геофизических данных, в частности, для выявления и анализа разломов.

В настоящих материалах было представлено предпочтительное раскрытие и осуществление заявленного изобретения, которое не должно использоваться как ограничивающее иные, частные воплощения его реализации, которые не выходят за рамки испрашиваемого объема правовой охраны и являются очевидными для специалистов в соответствующей области техники.

ФОРМУЛА ИЗОБРЕТЕНИЯ

1. Способ обучения нейронных сетей на основе физического моделирования геофизических данных, включающий этапы, на которых:

осуществляется генерация модели отражающих границ, а также формируется разметка разломной тектоники за счет создания двухмерных или трехмерных отражающих моделей;

осуществляется создание модели интервальных скоростей между отражающими границами за счет формирования базовой скоростной модели и применения скоростных изменений, соответствующих структуре отражающей модели;

осуществляется подготовка данных для процедуры миграции с целью получения мигрированной сейсмике за счет создания сглаженных моделей интервальных скоростей, полученных на предыдущем этапе, при этом сглаженные модели используются в качестве входных данных для миграции и являются начальными скоростными моделями, которые уточняются посредством процедуры миграции;

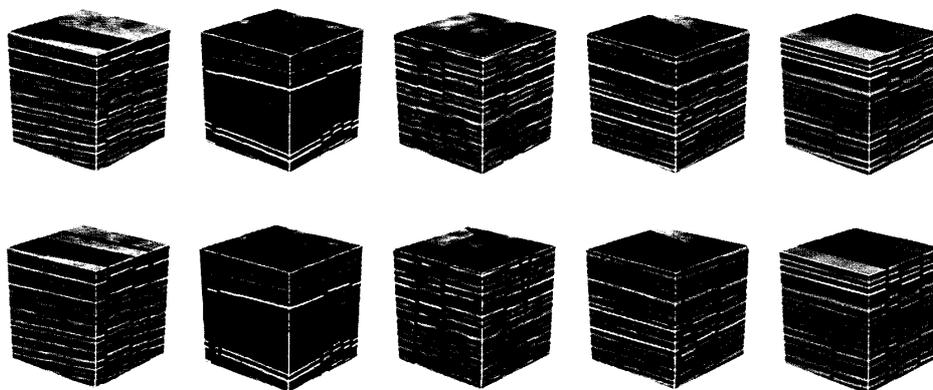
осуществляется миграция моделей и получение мигрированной сейсмике на котором скоростные модели, сформированные на предыдущем этапе, подвергаются миграции посредством алгоритмов LSRTM (Least-Squares Reverse Time Migration), а именно итерационный процесс LSRTM начинается с прямого моделирования начальной модели скоростей, полученной на предыдущем этапе, с учётом геометрии источников и приёмников, после чего следует обратная во времени миграция моделированных данных, далее полученные данные сравниваются с данными, полученными на предыдущем этапе прямым моделированием на моделях скоростей до сглаживания, а разница между ними определяет обновление скоростной модели, причем процесс повторяется в течение нескольких итераций, каждая из которых улучшает точность скоростной модели и качество мигрированных данных.

2. Способ по п.1, в котором на этапе подготовки данных для процедуры миграции, в качестве априорных данных для миграции используются сейсмограммы, полученные прямым моделированием до процедуры сглаживания.

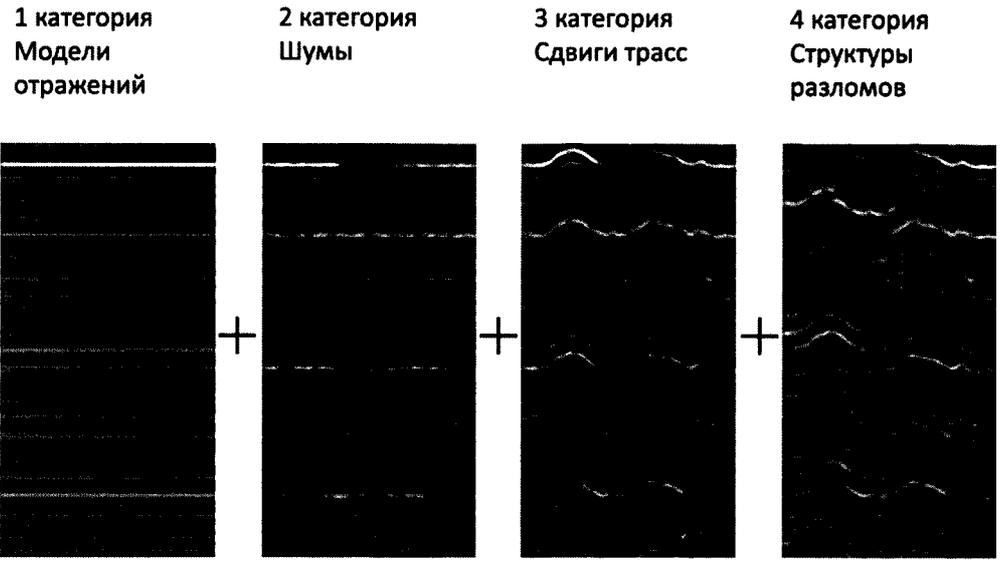
3. Способ по п.1, в котором на этапе подготовки данных для процедуры миграции для сглаживания используется Гауссова фильтрация.

4. Способ по п.1, в котором на этапе подготовки данных для процедуры миграции осуществляется подготовка сглаженных скоростных моделей для миграции, а именно задается сетка приёмников и источников на поверхности сглаженных скоростных моделей для последующих решений уравнения продольной волны для заданной модели среды внутри алгоритма миграции в обратном времени.

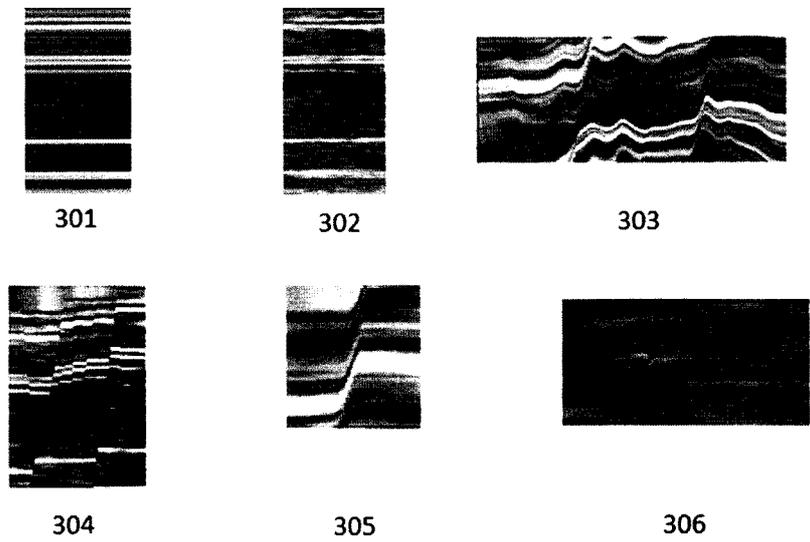
5. Способ по п.1, в котором на вход нейронная сеть принимает массивы сейсмических данных, полученных в ходе миграционного процесса, и информацию о разломах, сформированную на начальном этапе.



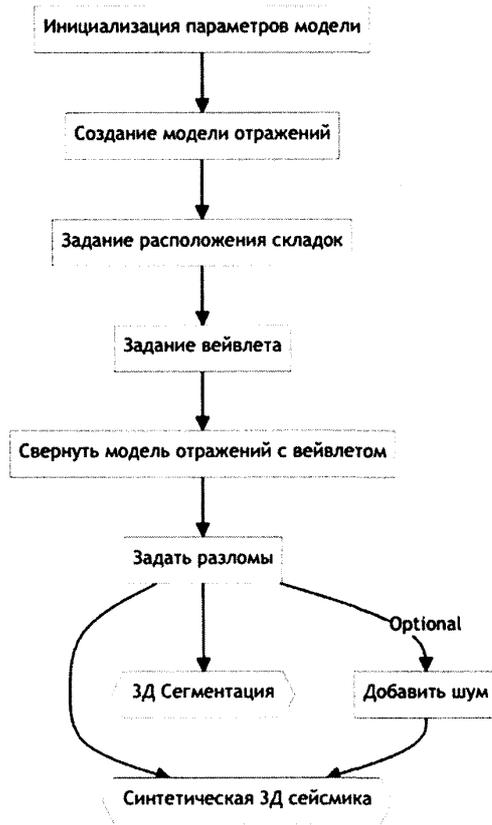
Фиг. 1



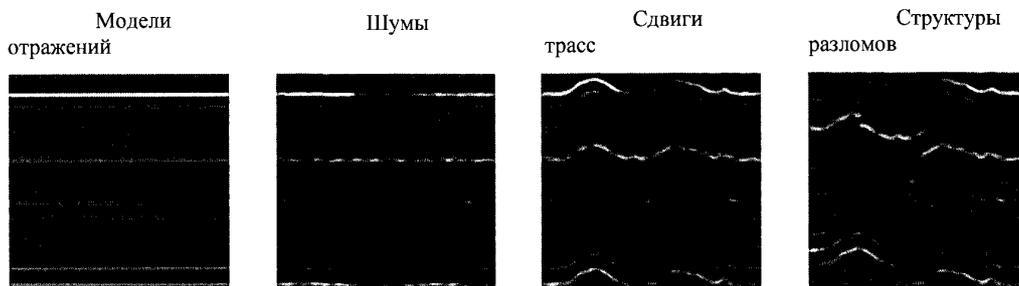
Фиг. 2



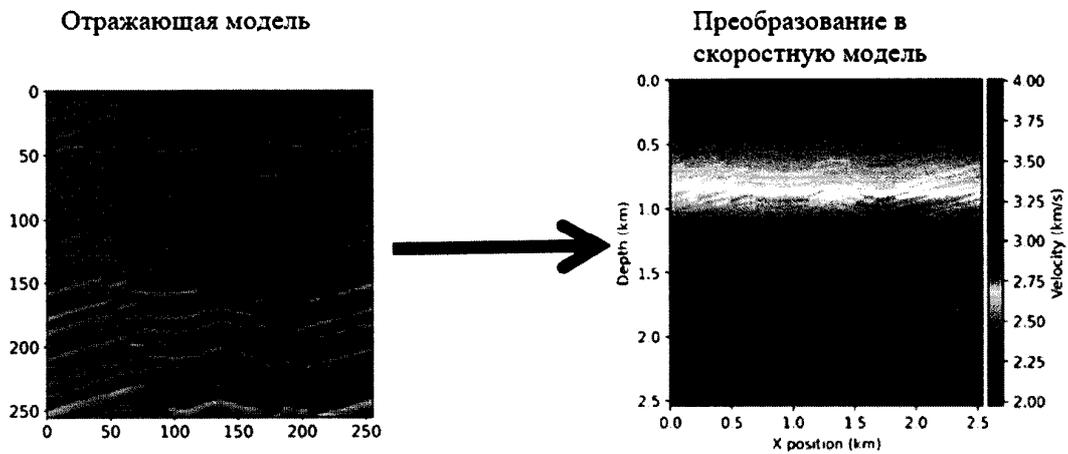
Фиг. 3



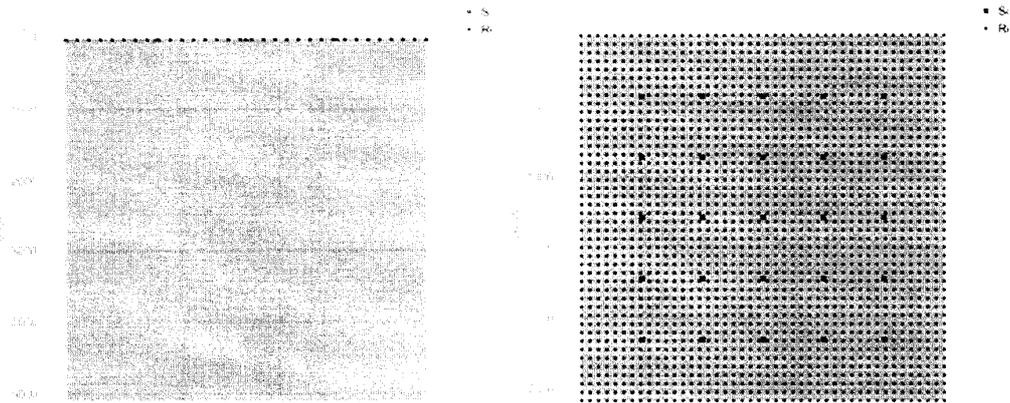
Фиг. 4



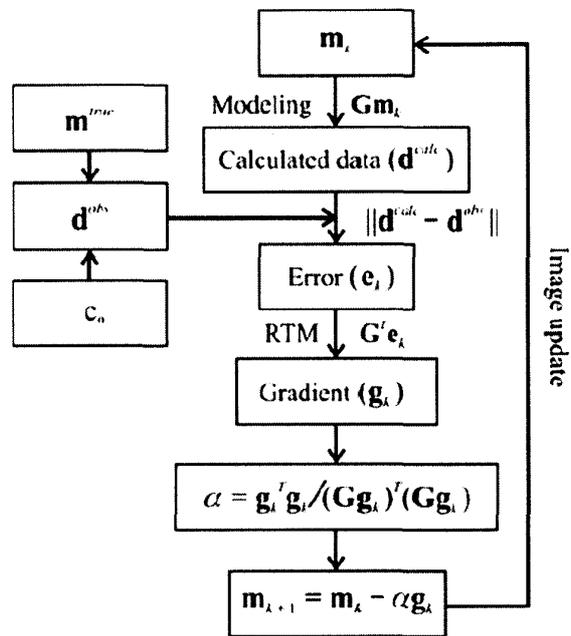
Фиг. 5



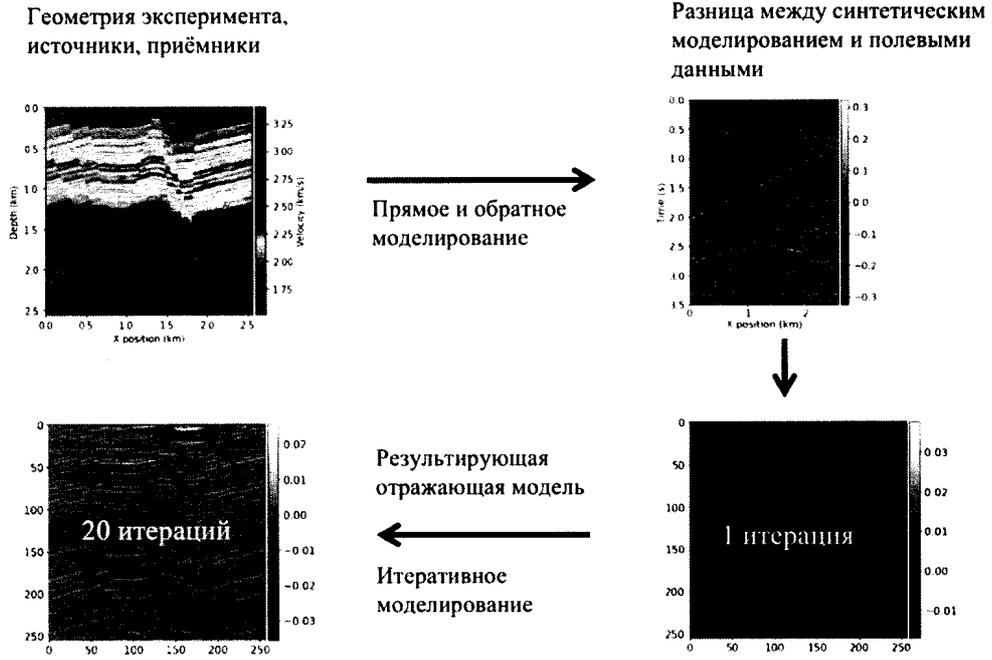
Фиг. 6



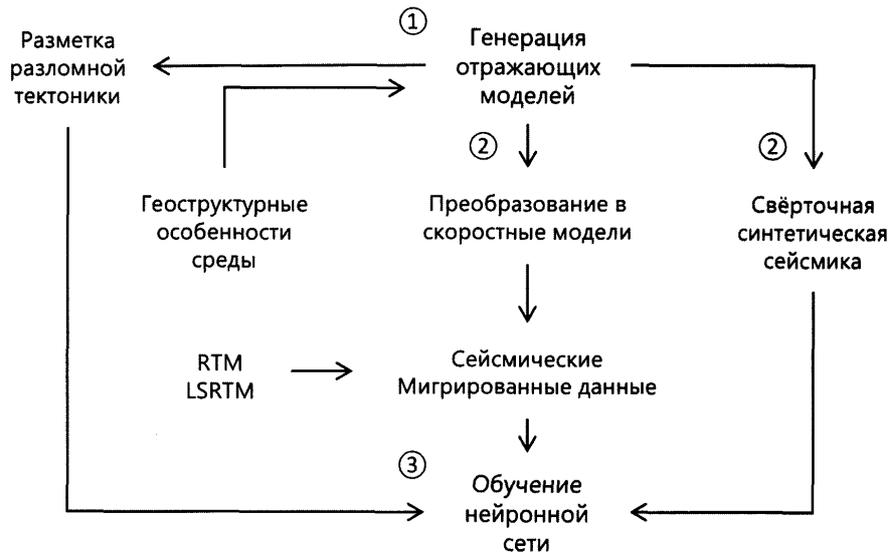
Фиг. 7



Фиг. 8



Фиг. 9



Фиг. 10

Label



Pred



Миграция

Pred



Синтетика

Label

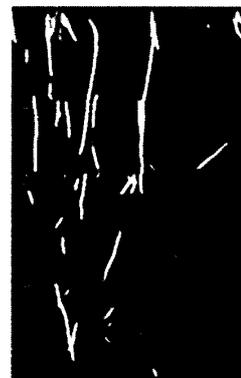


Pred



Миграция

Pred



Синтетика

Фиг. 11

