

ПРИМЕНЕНИЕ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВЕ ТРАНСФОРМЕРОВ В КАЧЕСТВЕ АЛГОРИТМА ДЛЯ СЕЙСМИЧЕСКОЙ АМПЛИТУДНОЙ ИНВЕРСИИ

В.Д. Гришко^{1,2,*}, А.А. Козяев¹, Е.Е. Шилов¹, Д.А. Петров¹

¹ООО «РН-КрасноярскНИПИнефть», РФ, Красноярск

²ФГАУ ВО «Сибирский федеральный университет», РФ, Красноярск

Электронный адрес: GrishkoVD@knipi.rosneft.ru

Введение. Сейсмическая амплитудная инверсия позволяет переходить от стандартных сейсмических кубов и разрезов к физически значимым параметрам, таким как акустический импеданс (АИ), плотность и т.д., для проведения количественной интерпретации. Однако задача инверсии является некорректно поставленной из-за многовариантности и неустойчивости решений, а также ограниченности частотного диапазона сейсмических данных, что обычно требует использования итеративной оптимизации.

Целью данной работы является разработка и апробация метода сейсмической амплитудной инверсии в акустическом варианте с применением генеративно-сопоставительных нейронных сетей (GAN) без необходимости построения низкочастотной модели и извлечения импульса из скважинных данных. Данный метод направлен на минимизацию степени свободы алгоритма инверсии, полагаясь на то, что нейронные сети способны выделить всю необходимую информацию напрямую из входных данных, а также на существенное сокращение времени, требуемого для прогноза распространения акустических свойств.

Материалы и методы. В исследовании рассматриваются три сценария архитектур моделей для решения задачи прогноза псевдоакустического каротажа, каждый из которых различается количеством нейросетей. Каждый из сценариев адаптирован к специфике реальных месторождений, в которых количество скважин для анализа часто ограничено. Предложенный подход к обучению, используемый в нейронных сетях GAN, применяется для регуляризации моделей и борьбы с переобучением. Разработанный метод тестируется на реальных данных Восточной Сибири.

Результаты нового метода сравниваются с результатами стандартного алгоритма акустической инверсии на основе модели (Model-based). Предлагаемый метод демонстрирует сопоставимые значения метрик количественной оценки и качественного анализа, требуя значительно меньше времени для получения прогноза.

Заключение. Рекомендованный в работе метод демонстрирует высокую эффективность использования технологий глубокого обучения для решения задач инверсии сейсмических данных и может рассматриваться как экспресс метод акустической инверсии.

Ключевые слова: сейсмическая амплитудная инверсия, акустическая инверсия, глубокое обучение, генеративно-сопоставительные нейронные сети

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Гришко В.Д., Козяев А.А., Шилов Е.Е., Петров Д.А. Применение генеративно-сопоставительных нейронных сетей на основе трансформеров в качестве алгоритма для сейсмической амплитудной инверсии. ПРОНЕФТЬ. Профессионально о нефти. 2025;10(1):146–155. <https://doi.org/10.51890/2587-7399-2025-10-1-146-155>

Статья поступила в редакцию 02.12.2024

Принята к публикации 24.01.2025

Опубликована 31.03.2025

APPLICATION OF TRANSFORMERS BASED GENERATIVE ADVERSARIAL NEURAL NETWORKS AS AN ALGORITHM FOR SEISMIC AMPLITUDE INVERSION

Vladimir D. Grishko^{1,2,*}, Andrey A. Kozyayev¹, Egor E. Shilov¹, Denis A. Petrov¹

¹LLC "RN-KrasnoyarskNIPIneft", RF, Krasnoyarsk

²Siberian Federal University, RF, Krasnoyarsk

E-mail: GrishkoVD@knipi.rosneft.ru

Introduction. Seismic amplitude inversion enables the transition from wavefield amplitudes to the distributions of physical properties and the prediction of their propagation. However, the inversion problem is often ill-posed due to solution non-uniqueness and instability, as well as the limited frequency range of seismic data, which typically necessitates iterative optimization.

Aim. The objective of this study is to develop and test a method for impedance inversion using Generative Adversarial Networks (GAN) without the need for constructing a low-frequency model or extracting the impulse from well log data. This method aims to minimize the degrees of freedom of the inversion algorithm, relying on neural networks' ability to extract all necessary information directly from the input data, and significantly reducing the time required for predicting the propagation of acoustic properties.

Materials and methods. The study examines three model architecture scenarios for predicting pseudo-acoustic logging, each differing in the number of neural networks. Each scenario is adapted to the specifics of real data, where the number of wells available for analysis is often limited. The proposed training approach used in GANs is applied for solve model regularization and overfitting tasks. The developed method is tested on real data from a site in Eastern Siberia.

Results. The results of the new method are compared with those of the standard model-based acoustic inversion algorithm. Our method demonstrates comparable metrics in quantitative evaluation and qualitative analysis, requiring significantly less time to obtain the forecast.

Conclusion. Our method demonstrates high efficiency in using deep learning technologies to solve seismic data inversion problems and can be considered as a rapid method for acoustic inversion.

Keywords: seismic inversion, impedance inversion, deep learning, generative adversarial networks

Conflict of Interest: the authors declare no conflict of interest.

For citation: Grishko V.D., Kozyayev A.A., Shilov E.E., Petrov D.A. Application of transformers based generative adversarial neural networks as an algorithm for seismic amplitude inversion. PRONEFT. Professionally about oil. 2025;10(1):146–155. <https://doi.org/10.51890/2587-7399-2025-10-1-146-155>

Manuscript received 02.12.2024

Accepted 24.01.2025

Published 31.03.2025

ВВЕДЕНИЕ

Сейсмическая амплитудная инверсия (далее инверсия) — это семейство алгоритмов, позволяющих переходить от стандартных сейсмических кубов и разрезов к физически значимым параметрам, таким как акустический импеданс (АИ), плотность и т.д., для проведения количественной интерпретации.

Количественная интерпретация опирается на взаимозависимость физических параметров, определяемых по геофизическим исследованиям скважин (ГИС) и получаемых по результатам инверсии, а также статистической зависимости таких важных свойств изучаемого пласта как литология, коэффициент пористости и т.д. с этими физическими параметрами (АИ и т.д.).

Инверсия получила широкое распространение при поисках, разведке и изучении месторождений углеводородов (УВ). Процедуры инверсии используются на большинстве проектов по интерпретации данных сейсморазведки, что свидетельствует об актуальности темы.

Математически задача инверсии заключается в нахождении такой модели среды m , по которой бы рассчитанное с помощью известного оператора A геофизическое поле d_{synt} наилучшим образом соответствовало наблюдаемому d_{obs} . Тогда предполагается, что подобранная модель m близка к реальной геологической обстановке m_{real} .

Такая задача является некорректно поставленной [1] из-за:

неединственности решения: один и тот же сейсмический разрез может соответствовать бесконечному множеству геологических моделей;

неустойчивости решения: помехи в геофизических данных ведет к увеличению степени свободы в пространстве поиска оптимальной модели.

Кроме того, в контексте сейсмической инверсии существует проблема ограниченности частотного диапазона сейсмических данных по сравнению с данными скважин.

В силу описанных ограничений многие стандартные подходы к решению задачи инверсии основаны на минимизации параметрического функционала, включающего невязку между расчетным и наблюдаемым сейсмическими полями и функционал регуляризации, который позволяет ограничить пространство поиска искомой модели.

Существует множество алгоритмов сейсмической инверсии, которые, в свою очередь, делятся на акустическую и упругую инверсии, детерминистическую и стохастическую и т.д. [2]. Современные аналитические алгоритмы, инверсия редких импульсов и инверсия на основе модели, позволяют добиться наиболее корректных моделей распределения физических свойств в межскважинном пространстве, однако дополнительно требуют извлечения импульса из скважинных данных для решения прямой задачи и построения фоновой низкочастотной модели для перехода к абсолютным значениям упругих

$$A(m) = d_{synt}; d_{synt} \rightarrow d_{obs}. \quad (1)$$

свойств в случае инверсии редких импульсов и для начального приближения в случае инверсии на основе модели. С другой стороны, активно развиваются алгоритмы на основе глубокого обучения, которые позволяют решать некоторые из проблем аналитических подходов и повысить скорость выполнения

и реальные сейсмические данные, в исследованиях также демонстрируется превосходство GAN по сравнению со стандартными CNN моделями по ряду метрик качества.

ЦЕЛЬ

Целью данной работы является разработка и апробация метода сейсмической инверсии в акустическом варианте с применением генеративно-состязательных нейронных сетей без дополнительного построения низкочастотной модели и извлечения импульса из скважин. Предлагая данный метод, авторы стремились, с одной стороны, сократить количество степеней свободы алгоритма инверсии, полагаясь на то, что нейронные сети выделяют всю необходимую информацию напрямую из входных данных, с другой стороны, значительно уменьшить время, требуемое на получение прогноза распространения акустических свойств.

В ходе работы рассмотрены три сценария архитектур моделей для решения задачи прогноза акустического импеданса в порядке не возрастания количества нейросетей в них. Результаты работы предложенного метода демонстрируются на реальных данных, полученных на месторождении, расположенном в Восточной Сибири, и сравниваются со стандартным алгоритмом акустической инверсии на основе модели (model-based).

МЕТОД

В основе всех моделей глубокого обучения лежат данные, на которых обучаются модели. Сокращая выбранный функционал ошибки, глубокие нейронные сети аппроксимируют зависимость между входными и выходными данными без явного программирования формул или правил. Исходными данными для сейсмической инверсии в акустическом варианте являются полнократный сейсмический куб и значения акустического импеданса по ГИС. Пары кривых АИ и соответствующих им сейсмических трасс являются «размеченной» обучающей выборкой. При этом количество скважинных данных во много раз меньше количества сейсмических трасс, что сильно ограничивает «размеченную» выборку и осложняет процесс обучения устойчивой модели глубокого обучения (ГО). В таких случаях уместно применять метод обучения с частичным привлечением учителя, в котором неразмеченным данным сопоставляется псевдоразметка. В предложенном методе

РАЗРАБОТАН И АПРОБИРОВАН АЛГОРИТМ СЕЙСМИЧЕСКОЙ ИНВЕРСИИ НА ОСНОВЕ ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ (GAN), ЧТО ПОЗВОЛЯЕТ БЕЗ ПОСТРОЕНИЯ НИЗКОЧАСТОТНОЙ МОДЕЛИ И ИЗВЛЕЧЕНИЯ ИМПУЛЬСА ИЗ СКВАЖИННЫХ ДАННЫХ ВЫДЕЛЯТЬ ИЗ ВХОДНЫХ ДАННЫХ ВСЮ НЕОБХОДИМУЮ ИНФОРМАЦИЮ И СОКРАТИТЬ ВРЕМЯ ДЛЯ ПРОГНОЗА РАСПРОСТРАНЕНИЯ АКУСТИЧЕСКИХ ПАРАМЕТРОВ.

работ или добавить вариативность в полученные результаты [3].

Методы на основе глубокого обучения (ГО) интересны в первую очередь возможностью аппроксимации функциональной зависимости между входными и выходными данными. Так в работе [4] используют сверточные нейронные сети (CNN) для инверсии акустического импеданса. В работе [5] исследователи применяют предобученную базовую модель Seismic-Foundation-Model (SFM) для инверсии коэффициентов отражения по данным сейсмики.

Основными источниками «размеченной» информации для алгоритмов глубокого обучения в области сейсмической амплитудной инверсии являются данные ГИС, однако в реальных проектах их количество, как правило, ограничено, из-за чего применение классического метода обучения с учителем приводит к переобучению и слабой прогнозной способности алгоритма. С другой стороны, огромный объем «неразмеченной» информации в виде сейсмического куба в случае данных сейсморазведочных работ (СРР) 3D при таком подходе остается вне поля зрения модели. Учесть одновременно «размеченные» и «неразмеченные» данные возможно при применении метода обучения нейронных сетей с частичным привлечением учителя, в котором «неразмеченным» данным присваивается псевдоразметка с помощью различных техник.

Выдающихся результатов в области безусловной и условной генерации данных достигли генеративно-состязательные нейронные сети (GAN). В работе [6] показаны GAN в сочетании с методом обучения с частичным привлечением учителя для инверсии акустического импеданса, используя синтетические

использована дополнительная нейронная сеть $\bar{B}$ для преобразования кривых акустического импеданса в сейсмические трассы для использования всех сейсмических трасс при обучении модели ГО. Так, во время обучения генератора $\bar{A}$ кривых акустического импеданса по сейсмическим данным восстанавливалась некоторая F с условиями:

$$\begin{cases} m = F(d_{obs}), \\ d_{obs} = P[F(d_{obs})], \\ d_{obs} = P(m_{obs}), \end{cases} \quad (2)$$

где m — модель акустического импеданса, d_{obs} — наблюдаемое сейсмическое поле, m_{obs} — данные АИ из скважин, P — функция, задаваемая моделью ГО $\bar{B}$, преобразующая кривые АИ в сейсмические трассы.

Стоит обратить внимание, что в отличие от аналитических алгоритмов инверсии в предложенном методе не используются низкочастотные модели, извлеченный импульс и модель сверточной трассы, позволяя нейросетевым моделям самостоятельно искать необходимую информацию в исходных данных.

Все рассмотренные ниже архитектуры содержат две нейронные сети генератора: модель $\bar{A}$, преобразующая сейсмические трассы в кривые АИ и восстанавливающая функцию F ; модель $\bar{B}$, преобразующая кривые АИ в сейсмические трассы восстанавливающая функцию P .

А. Сценарий 1. Ошибка MSE

В первом сценарии использованы две нейронные сети $\bar{A}$ и $\bar{B}$. Во время обучения, сначала обучается нейронная сеть $\bar{B}$ на небольшом объеме размеченных данных. На вход модели подается двухканальный временной ряд, первый канал — АИ, второй — рассчитанные по АИ коэффициенты отражения. Стоит учесть, что данные второго канала вполне могут быть рассчитаны самой нейронной сетью в латентном пространстве признаков, однако они явно подаются как атрибут, имеющий физическое обоснование. Выходом модели являются сейсмические трассы, соответствующие поданным импедансом. В силу того что функциональная зависимость P проще зависимости F и успешно решается с помощью математической модели сверточной трассы, предполагается, что даже небольшой выборки будет достаточно для обучения нейронной сети. Замена этой математической модели на нейронную сеть $\bar{B}$, позволяет, с одной стороны, избавиться от необходимости извлечения импульса из скважинных данных, с другой стороны — получить более комплексную зависимость,

в неявном виде учитывающую наличие шума в данных и положение трассы в пространстве. При обучении нейронной сети минимизируется функционал среднеквадратичной ошибки (MSE).

$$L_{MSE}(B) = E[\|d_{obs} - B(m_{obs})\|_2^2]. \quad (3)$$

При обучении модели $\bar{A}$ были использованы веса обученной модели $\bar{B}$. Входными для модели $\bar{A}$ являются сейсмические трассы, на выходе ожидаются восстановленные кривые АИ. На «размеченных» данных также была рассчитана среднеквадратичная ошибка (MSE). Для «неразмеченных» данных использовано циклическое преобразование: выбрав некоторую сейсмическую трассу s , она была преобразована с помощью A в кривую АИ $\tilde{a}$, затем с помощью уже обученной модели $\bar{B}$ выполнено обратное преобразование из $\tilde{a}$ в $\tilde{s}$. Считая, что нейронная сеть $\bar{B}$ корректно восстанавливает зависимость P , нейронной сети $\bar{A}$ нужно так преобразовать неразмеченные данные, чтобы исходная сейсмическая трасса s и восстановленная в результате циклического преобразования $\tilde{s}$ были идентичны. Итоговой функционал ошибки для нейронной сети $\bar{A}$ записывается следующим образом:

$$L(A) = \alpha L_{MSE}^{labeled}(A) + \beta L_{MSE}^{unlabeled}(A), \quad (4)$$

$$L(A) = \alpha E[\|m_{obs} - A(d_{obs}^l)\|_2^2] + \beta E[\|d_{obs} - B(A(d_{obs}^{ul}))\|_2^2], \quad (5)$$

где d_{obs}^l — сейсмические трассы из размеченной выборки, d_{obs}^{ul} — сейсмические трассы из неразмеченной выборки, α и β — коэффициенты.

Б. Сценарий 2. Ошибка MSE + cGAN

Несмотря на использование циклического преобразование для учета неразмеченных данных, минимизация функционала MSE может приводить к сильному переобучению в условиях довольно ограниченной «размеченной» выборки. Одним из способов борьбы с переобучением нейронных сетей является добавление регуляризирующего функционала в общий функционал ошибки. Нейронные сети GAN способны генерировать данные из случайного вектора z в заданном латентном пространстве. Такие нейронные сети состоят из двух частей: генератора G и дискриминатора D . Генератор G создает данные, соответствующие распределению признаков целевых примеров, дискриминатор D , в свою очередь, отличает целевые реальные данные и сгенерированные

генератором. Процесс обучения GAN можно представить как игру с нулевой суммой.

$$\min_G \max_D L(G, D) = E[\log D(x)] + E[\log 1 - D(G(z))], \quad (6)$$

Для того чтобы генерировать данные по некоторому предварительному условию, например метке класса, во время обучения вместо или совместно с вектором случайного шума на вход генератора подается векторизованное условие. На вход дискриминатора подается как условие, так и целевые данные, сгенерированные или реальные.

В контексте решаемой задачи использован дискриминатор как регуляризирующий функционал в общей функции ошибки нейросети $\bar{A}$. Благодаря добавлению данного слагаемого удалось достичь более обобщенного результата генерации кривых АИ и повысить робастность модели. В данной работе использована условная модель cGAN (conditional GAN) Вассерштейна с добавлением градиентного штрафа для устойчивого обучения модели дискриминатора на небольшом объеме данных.

$$L(A) = \alpha L_{MSE}^{labeled}(A) + \beta L_{MSE}^{unlabeled}(A) + \gamma L_{GAN}(A, D_A), \quad (7)$$

$$L_{GAN}(A, D_A) = -E[D_A(m, d)] + E[D_A(A(d), d)] + \lambda E[\|\nabla_{\tilde{m}} D_A(\tilde{m}, d)\|_2 - 1]^2], \quad (8)$$

где $\tilde{m}$ — случайная линейная интерполяция между каротажем АИ из скважины и сгенерированным нейронной сетью $\bar{A}$.

Таким образом, удалось скомбинировать ошибку MSE и cGAN, обучая нейронную сеть, генератор $\bar{A}$ как на «размеченных», так и на «неразмеченных» данных и дискриминатор D_A на размеченных данных с целью большей обобщающей способности модели.

В. Сценарий 3

Добавляя дискриминатор D_A , удалось решить задачу с переобучением модели $\bar{A}$ при небольшом объеме обучающих данных. Однако для обучения модели $\bar{B}$ в описанном подходе использован только «размеченный» набор данных. Поэтому в сложных геолого-геофизических условиях модель $\bar{B}$ может некорректно восстановить зависимость P , например из-за переобучения на шумных данных, что приведет к ошибочному циклическому преобразованию при обучении нейронной сети $\bar{A}$. Дополнительно учесть неразмеченные данные также возможно с помощью генеративно-состязательной нейронной сети.

Во время обучения нейронной сети $\bar{B}$ дополнительно использована ошибка безусловной

модель GAN Вассерштейна. Результирующий функционал ошибки принимает вид:

$$L(B) = \alpha L_{MSE}(B) + \beta L_{GAN}(B, D_B), \quad (9)$$

$$L_{GAN}(B, D_B) = -E[D_B(d)] + E[D_B(B(m))] + \lambda E[\|\nabla_{\tilde{d}} D_B(\tilde{d})\|_2 - 1]^2], \quad (10)$$

где D_B — безусловный дискриминатор, $\tilde{d}$ — случайная линейная интерполяция между реальной сейсмической трассой и сгенерированной нейронной сетью $\bar{B}$.

Идея использования безусловного дискриминатора, помимо регуляризации нейронной сети $\bar{B}$, заключается в изучении распределения характеристик сейсмических трасс по изучаемой площади. Каждая из моделей $\bar{A}$, $\bar{B}$, D_A , D_B помимо описанных входных данных дополнительно получает векторизованную информацию о положении входного временного ряда в пространстве. Использование этой информации при обучении позволяет построить более корректную зависимость P между данными АИ и сейсмическими трассами. Корректная зависимость P , в свою очередь, приведет к более стабильному обучению основной нейронной сети $\bar{A}$.

Схема сценария 3, содержащая элементы сценариев 1 и 2, приведена на рис. 1.

Г. Архитектура нейронных сетей и особенность реализации

Все из перечисленных нейронных сетей $\bar{A}$, $\bar{B}$, D_A , D_B основаны на архитектуре Трансформер [7] (Transformer), предназначенной для обработки последователей и активно используемой как в задачах обработки естественного языка, так и в задачах обработки изображений.

Входная последовательность данных, такие как кривые АИ или сейсмические трассы, разбивается на части, токены, по заданному числу отчетов. Полученная последовательность токенов суммируется с позиционными векторами, эмбедингами (positional embedding), вычисленными по синусоидальному закону, и описывающими положение каждого токена в 3-мерном пространстве изучаемого объекта. Благодаря такому механизму обработки последовательности становится возможным явно учитывать характеристики кривых как по глубине, так и по положению на 2D-сетке.

Нейронные сети генераторы $\bar{A}$, $\bar{B}$ состоят из кодировщика, включающего в себя несколько подряд идущих блоков трансформера, и сверточного декодера, преобразующий скрытый вектор, полученный кодировщиком в данные в исходном пространстве. В дискриминаторах D_A и D_B используется




Рис. 1. Схема модели глубокого обучения, описанная в сценарии 3 (Е.Е. Шилов, В.Д. Гришко)
 Fig. 1. Diagram of the deep learning model described in Scenario 3 (Egor E. Shilov, Vladimir D. Grishko)




Рис. 2. Архитектура нейронной сети генератора (Е.Е. Шилов, В.Д. Гришко)
 Fig. 2. Architecture of the generator neural network (Egor E. Shilov, Vladimir D. Grishko)

только часть кодировщика, однако дополнительно обучается специальный токен, обрабатывающийся со всей остальной последовательностью, значение которого является ответом модели дискриминатора. (рис. 2). Для нейронных сетей $\bar{A}$, D_A и $\bar{B}$, D_B были выбраны одинаковые параметры кодировщика: 12 блоков трансформера с размерностью скрытого вектора в 128 элементов и 8 блоков трансформера с размерностью скрытого вектора в 64 элемента, соответственно. Сверточный блок содержит два нейронных сверточных оператора, пакетную нормализацию и остаточное соединение. Особенностью реальных данных является разная глубина скважин. Для пакетной обработки нескольких скважин одновременно случайным образом выбирается длина обрабатываемой последовательности текущего пакета, затем из каждой кривой АИ или сейсмической трассы берется часть последовательности, выбранной длины, начиная со случайно определённого времени старта для каждой кривой. Абсолютное положение выбранных примеров задается с помощью позиционных векторов. Такое сэмпирование также добавляет стохастичность во время

обучения моделей, что может повысить их робастность и выразительность.

РЕЗУЛЬТАТ

Для апробации метода использованы данные, полученные на месторождении, расположенном в Восточной Сибири. Площадь изучаемого участка составляет 2000 тыс. км². В соответствии с петрофизическими исследованиями, проведенными на объекте, есть связь между значениями АИ и коэффициентом глинистости, что, в свою очередь, позволяет прогнозировать коллектор в целевом, рифейском интервале разреза. Наибольший интерес представляет интервал ниже предвендской эрозионной поверхности (отражающий горизонт (ОГ) R0 +30 мс). В рамках стандартного графа обработки и интерпретации выполнена акустическая инверсия с помощью алгоритма model-based, где используется низкочастотная модель (НЧМ) построенная по данным ГИС. Выборка скважин стандартно делится на используемые в НЧМ и тестовые, по которым оценивается качество инверсии.

Для обучения нейросетевого алгоритма использованы те же скважины, по которым построена НЧМ. Всего для исследования было доступно 30 скважин, 20 из которых использовались в обучающей выборке.

Дополнительным вызовом для предложенного метода является неравномерное распределение скважин как по латерали, так и по глубине. Глубже 1100 м (около — 2500 м) пробурены только 4 скважины (2 в обучающей выборке, 2 в тестовой). Нейросетевой алгоритм может оказаться непригоден для экстраполяции на более глубокие времена в силу и без того небольшой обучающей выборки.

В ходе работы нейронная сеть обучалась в течение 2000 эпох по трем сценариям, описанным в предыдущем пункте. После

выбора лучшей модели B' также в течение 2000 эпох обучалась модель А. В сценариях с наличием дискриминатора были выбраны коэффициенты для функционала ошибки GAN таким образом, чтобы его значение было одного порядка со значением MSE ошибки. В противном случае эффект от ошибки GAN либо становится незаметен, либо становится слишком велик, что ведет к ухудшению метрик качества. Для оптимизации функционалов ошибки использована градиентная оптимизация Adam со скоростью обучения (learning rate) в 0,0004.

Разрезы куба AI представлены на **рис. 3**. Заметно, как при усложнении модели улучшается прогностная способность алгоритма и устойчивость полученного решения. Если в первом сценарии ниже горизонта




Рис. 3. Разрезы AI полученные с помощью методов ГО и model-based инверсии: (а) первый сценарий; (б) второй сценарий; (в) третий сценарий, лучший результат среди методов ГО; (г) model-based инверсия. Скважина 2 является валидационной (Е.Е. Шилов, В.Д. Гришко)
Fig. 3. Acoustic Impedance sections obtained using deep learning methods and model-based inversion: (a) first scenario; (б) second scenario; (в) third scenario (the best result among deep learning methods); (г) model-based inversion. Well 2 is the validation well (Egor E. Shilov, Vladimir D. Grishko)

R0 не удается выделить блоковые структуры, то в 3 сценарии отчетливо видны все, в том числе крутонаклонные блоки. Заметная латеральная неоднородность результата предположительно вызвана чувствительностью моделей ГО к шуму, из-за чего даже на соседних трассах может колебаться значение прогнозного импеданса. Такая особенность предсказания в дальнейшем может быть компенсирована с помощью сглаживания или с помощью одновременного использования нескольких соседних трасс для расчёта значений АИ. На картах поверхности R0 + 30 мс (рис. 4) также наблюдается схожий характер распределения аномалий АИ по латерали.

Анализируя метрики качества на валидационных скважинах (табл. 1), также можно сделать вывод о высоком качестве прогноза по предложенному методу, сопоставимом со стандартным подходом. При этом необходимо отметить, что время, затраченное на расчёт куба АИ, по разработанному методу кратно меньше (с учётом создания НЧМ и т.д.).

Таблица 1. Оценка качества инверсии АИ по валидационным скважинам
Table 1. Assessment of the quality of Acoustic Impedance inversion by validation wells

	Предложенный метод (сценарий 3)	Model-based инверсия
Коэффициент корреляции	0,78	0,77
Коэффициент корреляции (целевой интервал)	0,71	0,7
Средняя абсолютная ошибка*	1,30	1,26
Средняя абсолютная ошибка* (целевой интервал)	1,54	1,44

* Стандартизированные данные (среднее 0, дисперсия 1)

* Standardized data (mean 0, variance 1)

ВЫВОДЫ

В статье продемонстрирован метод сейсмической амплитудной инверсии в акустическом варианте с применением генеративно-состязательных нейронных сетей на основе архитектуры Трансформер. Учитывая специфику реальных проектов, на которых количество скважин, т.е. «размеченных» данных, как правило, сильно ограничено, в данной работе использованы различные техники




Рис. 4. Срезы куба АИ на уровне R0 + 30 мс. Слева — результат модели ГО сценария 3, справа — результат model-based инверсии. Черными точками показаны валидационные скважины (Е.Е. Шилов, В.Д. Гришко)

Fig. 4. Slices of the Acoustic Impedance cube at R0 + 30 ms. The left panel shows the result of deep learning model from Scenario 3, and the right panel shows the result of model-based inversion. Black dots indicate validation wells (Egor E. Shilov, Vladimir D. Grishko)

для повышения прогнозной способности алгоритма. Для учета как «размеченной» информации пар каротажа АИ и соответствующих им сейсмических трасс, так и «неразмеченной» использовано циклическое преобразование с помощью обучения двух моделей нейронных сетей. Одна из моделей решает основную задачу преобразования сейсмического куба в кривые АИ, вторая является вспомогательной и решает более простую задачу преобразования значений АИ по ГИС в сейсмическую трассу. В ходе экспериментов также показано, что при обучении нейронных сетей с помощью минимизации только MSE функционала происходит потеря предсказательной способности и переобучения модели на обучающих скважинах. Для минимизации этого эффекта использован функционал ошибки GAN Вассерштейна дополнительно к MSE. Роль дискриминатора в таком случае может интерпретироваться как регуляризация, направленная на генерацию более обобщенного результата. Использование дискриминаторов для обучения как основной и вспомогательной моделей позволило добиться наиболее релевантного прогноза свойств среды в межскважинном пространстве. Новизной работы является использование

нейронных сетей архитектуры Трансформер с абсолютным позиционным кодированием как для генераторов, так и для дискриминаторов.

Предложенный авторами метод позволяет получить оценку упругих свойств разреза без дополнительного построения низкочастотной модели и извлечения импульса из скважин, используя только сейсмический куб амплитуд и значения АИ по ГИС, и может рассматриваться как экспресс-метод акустической инверсии. Для апробации метода были использованы реальные данные, полученные на территории Восточной Сибири, что позволило добиться результата, сопоставимого по метрикам качества с результатом наиболее часто используемого алгоритма model-based инверсии. При этом время обучения нейронных сетей и расчета куба АИ на тестируемом объекте составило менее одного часа, что на два порядка меньше времени, затраченного на расчёт инверсии по стандартному графу. На данный момент в предложенном методе остался открытым вопрос о необходимом минимальном количестве скважин для инверсии АИ. Таким образом, дальнейшие исследования связаны с модификацией алгоритма для устойчивости к малому числу скважин.

Список литературы

1. Жданов М.С. Теория обратных задач и регуляризации в геофизике. М.: Научный мир, 2007. 712 с
2. Данько Д.А. Разработка принципов изучения нетрадиционных глинистых коллекторов на основе петроупругого моделирования и амплитудной инверсии сейсмических данных: дис. ... канд. геол.-мин. наук [Место защиты: Рос. гос. ун-т нефти и газа им. И.М. Губкина]. — Москва, 2018. — 273 с.
3. Kim Y., Nakata N. Geophysical inversion versus machine learning in inverse problems, Lead. Edge, 2018, vol. 37, no. 12, pp. 894–901.
4. Wu B., Meng D., Wang L., Liu N., Wang Y. Seismic impedance inversion using fully convolutional residual network and transfer learning, IEEE Geosci. Remote Sens. Lett., 2020, vol. 17, no. 12, pp. 2140–2144.
5. Sheng H., Wu X., Si X., Li J., Zhang S., Duan X. Seismic Foundation Model (SFM): All-Purpose Feature Extraction from Seismic Data for Diverse Geophysical Applications, 85th EAGE Annual Conference & Exhibition, 2024, p. 1–5.
6. Meng D., Wu B., Wang Z., Zhu Z. Seismic impedance inversion using conditional generative adversarial network, IEEE Geoscience and Remote Sensing Letters, 2021, vol. 19, p. 1–5.
7. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. "Attention is all you need," Advances in neural information processing systems, vol. 30, 2017.

References

1. Zhdanov M.S. Theory of Inverse Problems and Regularization in Geophysics. Moscow: Nauchny Mir, 2007, 712 p.
2. Danko D.A. Development of principles for studying unconventional clay reservoirs based on petroelastic modeling and amplitude inversion of seismic data. 2018, 273 p.
3. Kim Y., Nakata N. Geophysical inversion versus machine learning in inverse problems, Lead. Edge, 2018, vol. 37, no. 12, pp. 894–901.
4. Wu B., Meng D., Wang L., Liu N., Wang Y. Seismic impedance inversion using fully convolutional residual network and transfer learning, IEEE Geosci. Remote Sens. Lett., 2020, vol. 17, no. 12, pp. 2140–2144.
5. Sheng H., Wu X., Si X., Li J., Zhang S., Duan X. Seismic Foundation Model (SFM): All-Purpose Feature Extraction from Seismic Data for Diverse Geophysical Applications, 85th EAGE Annual Conference & Exhibition, 2024, p. 1–5.
6. Meng D., Wu B., Wang Z., Zhu Z. Seismic impedance inversion using conditional generative adversarial network, IEEE Geoscience and Remote Sensing Letters, 2021, vol. 19, p. 1–5.
7. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. "Attention is all you need," Advances in neural information processing systems, vol. 30, 2017.

ВКЛАД АВТОРОВ / AUTHOR CONTRIBUTIONS

В.Д. Гришко — разработал и обучил алгоритмы глубокого обучения для инверсии акустического импеданса по данным сейсмики и скважин. Провел количественную оценку результатов по установленным метрикам качества.

А.А. Козяев — осуществлял общее и методическое руководство. Оказал экспертную поддержку в анализе полученных результатов.

Е.Е. Шилов — оказал экспертную поддержку в анализе полученных результатов. Предоставил графические материалы.

Д.А. Петров — оказал экспертную поддержку в разработке алгоритма и анализе полученных результатов.

Vladimir D. Grishko — developed and trained deep learning algorithms for acoustic impedance inversion using seismic and well log data. Conducted quantitative evaluation of the results based on established quality metrics.

Andrey A. Kozyayev — provided overall and methodological supervision. Offered expert support in the analysis of obtained results.

Egor E. Shilov — provided expert support in the analysis of obtained results. Supplied graphic materials.

Denis A. Petrov — provided expert support in developing the algorithm and support in the analysis of obtained results.

СВЕДЕНИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Владимир Дмитриевич Гришко* — геофизик ООО «РН-КрасноярскНИПИнефть», ФГАОУ ВО «Сибирский федеральный университет»
e-mail: GrishkoVD@knipi.rosneft.ru
660098, Россия, г. Красноярск, ул. 9 Мая, д. 65д.

Андрей Александрович Козяев — кандидат геолого-минералогических наук, начальник управления, ООО «РН-КрасноярскНИПИнефть»

Егор Евгеньевич Шилов — геолог
ООО «РН-КрасноярскНИПИнефть»

Петров Денис Александрович — начальник отдела, ООО «РН-КрасноярскНИПИнефть»

Vladimir D. Grishko* — Geophysicist at "RN-KrasnoyarskNIPIneft" LLC, Siberian Federal University (SFU)
e-mail: GrishkoVD@knipi.rosneft.ru
65D, 9th May Street, 660098, Krasnoyarsk, Russia.

Andrey A. Kozyayev — Cand. Sci. (Geol.-Min.), Head of Department, "RN-KrasnoyarskNIPIneft" LLC

Egor E. Shilov — Geologist at "RN-KrasnoyarskNIPIneft" LLC

Denis A. Petrov — Department manager, "RN-KrasnoyarskNIPIneft" LLC

* Автор, ответственный за переписку / Corresponding author