

АВТОМАТИЗАЦИЯ МЕТОДА АНАЛИЗА И ИНВЕРСИИ ПОВЕРХНОСТНЫХ ВОЛН ПУТЕМ ПРИМЕНЕНИЯ НЕЙРОННЫХ СЕТЕЙ

© Коллектив авторов,
2025



А.В. Яблоков^{1,2,3,*}, А.М. Камашев^{1,2}, М.В. Моисеев^{1,2}

¹ФГБУН «Институт нефтегазовой геологии и геофизики им. А.А. Трофимука» СО РАН, РФ, Новосибирск

²ФГАОУ ВО «Новосибирский национальный исследовательский государственный университет», РФ, Новосибирск

³ФГБУН «Институт физики Земли им. О.Ю. Шмидта» РАН, РФ, Москва

Электронный адрес: yablokovav@ipgg.sbras.ru

Введение. Метод анализа и инверсии поверхностных волн (SWI) эффективен для построения скоростной модели верхней части геологического разреза (ВЧР), обладая высокой помехоустойчивостью и не требуя специализированной системы наблюдения. Однако ручное извлечение дисперсионных характеристик поверхностных волн, необходимость настройки обратных операторов делает SWI трудоемким и непрактичным при обработке больших объемов данных. Разработка алгоритмов извлечения дисперсионных кривых и их инверсии на основе методов глубокого машинного обучения позволяет автоматизировать SWI с существенным ускорением всех его этапов, решая проблему субъективности ручной обработки и высоких требований к вычислительным ресурсам.

Цель. Ускорение и автоматизация построения скоростной модели ВЧР в ходе обработки сейсморазведочных данных по методу SWI с использованием нейронных сетей глубокого обучения.

Материалы и методы. Для ускорения и автоматизации метода SWI применяется глубокое машинное обучение: сверточная модель типа автоэнкодер и полносвязанная нейронная сеть. Тестирование разработанных алгоритмов выполняется на синтетических данных сейсморазведки, рассчитанных методом матричного пропагатора. Для апробации метода SWI используются полевые данные наземной сейсморазведки.

Результаты. Разработанные архитектуры нейронных сетей обеспечивают высокую точность автоматического извлечения и инверсии дисперсионных кривых поверхностных волн. Средние абсолютные процентные ошибки составили 1 % для извлеченных кривых и 5 % для восстановленных скоростных моделей на тестовом наборе данных. Разработанные алгоритмы применены для автоматизированного построения модели ВЧР по реальным сейсморазведочным данным нефтегазового месторождения в Западной Сибири.

Заключение. Комплекс разработанных алгоритмов на основе обученных нейронных сетей представляет собой новую эффективную реализацию метода SWI. Он позволяет автоматизировать и значительно ускорить построение ВЧР путем обработки данных поверхностных волн.

Ключевые слова: поверхностные волны, спектральный анализ, инверсия, дисперсионные кривые, нейронные сети

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Финансирование: исследование выполнено при поддержке совместного гранта Российского научного фонда и Правительства Новосибирской области № 23-27-10042, <https://rscf.ru/project/23-27-10042/>.

Для цитирования: Яблоков А.В., Камашев А.М., Моисеев М.В. Автоматизация метода анализа и инверсии поверхностных волн путем применения нейронных сетей. ПРОНЕФТЬ. Профессионально о нефти. 2025;10(1):136–145. <https://doi.org/10.51890/2587-7399-2025-10-1-136-145>

Статья поступила в редакцию 02.12.2024

Принята к публикации 24.01.2025

Опубликована 31.03.2025

AUTOMATION OF SURFACE WAVE ANALYSIS AND INVERSION METHOD BY APPLICATION OF NEURAL NETWORKS

Alexandr V. Yablokov^{1,2,3,*}, Aleksandr M. Kamachev^{1,2}, Mikhail V. Moiseev^{1,2}

¹Trofimuk Institute of Petroleum Geology and Geophysics of SB RAS, RF, Novosibirsk

²Novosibirsk State University, RF, Novosibirsk

³Schmidt Institute of Physics of the Earth of the Russian Academy of Sciences, RF, Moscow

E-mail: yablokovav@ipgg.sbras.ru

Introduction. Surface wave analysis and inversion (SWI) is a valuable tool for constructing near-surface velocity models. It offers high noise immunity and does not require specialized acquisition systems. However, manual extraction of surface wave dispersion characteristics and the need for inverse operator fitting make SWI time-consuming and impractical for large datasets.

Aim. This study aims to accelerate and automate near-surface velocity model construction using deep learning neural networks within the SWI framework.

Materials and methods. Deep machine learning methods, including a convolutional autoencoder model and a fully-connected neural network, were applied to achieve this goal. The developed algorithms were tested on synthetic seismic data generated using the matrix propagator method and validated using field data from ground seismic surveys.

Results. The proposed neural network architectures demonstrate high accuracy in automatically extracting and inverting surface wave dispersion curves. The mean absolute percentage error for extracted curves was 1 %, and 5 % for reconstructed velocity models on the test dataset. The developed algorithms were successfully applied to real seismic data from an oil and gas field in Western Siberia for automated near-surface model construction.

Conclusions. The set of developed algorithms, based on trained neural networks, offers a new and effective implementation of the SWI method. It automates and significantly accelerates near-surface model construction through the processing of surface wave data, overcoming the limitations of manual methods and providing a powerful tool for seismic analysis.

Keywords: surface waves, spectral analysis, inversion, dispersion curves, neural networks

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

Financing: the research was supported by the joint grant of the Russian Science Foundation and the Government of the Novosibirsk Region No. 23-27-10042, <https://rscf.ru/project/23-27-10042/>.

For citation: Yablokov A.V., Kamachev A.M., Moiseev M.V. Automation of surface wave analysis and inversion method by application of neural networks. PRONEFT. Professionally about oil. 2025;10(1):136–145. <https://doi.org/10.51890/2587-7399-2025-10-1-136-145>

Manuscript received 02.12.2024

Accepted 24.01.2025

Published 31.03.2025

ВВЕДЕНИЕ

Методы анализа и инверсии поверхностных волн (SWI или surface waves inversion) применяются для построения скоростной модели верхней части геологического разреза (ВЧР) [1], мониторинга физико-механических параметров грунтов [2], шумоподавления [3], определения статических поправок годографов отраженных волн [4] и др. задач. Классический подход к обработке данных поверхностных волн заключается в извлечении и инверсии дисперсионных кривых, описывающих зависимость фазовой скорости поверхностной волны Релея (V_R) от частоты (f). Они извлекаются путем ручного или полуавтоматического пикирования дисперсионного закона на спектральных изображениях сейсмограмм в $V_R - f$ области. Такая процедура является трудоемкой и субъективной, т.к. из-за осложнения шумом $V_R - f$ область зачастую представляет собой распределение прерывистых всплесков амплитуд и обработчик пикирует дисперсионный закон, основываясь на собственном опыте. Автоматизация извлечения дисперсионных кривых становится необходимой при обработке больших объемов сейсморазведочных данных, так как ручное пикирование становится непрактичным. В последние годы нейронные сети все чаще демонстрируют способность выделять определенные объекты на изображениях со схожими характеристиками: их распознавание на фотографиях, диагностика

рентгеновских снимков и др. По аналогии с этими задачами, нейронные сети могут успешно выявлять сложные закономерности в $V_R - f$ области, описывающие нелинейный дисперсионный закон поверхностной волны. Инверсия дисперсионных кривых выполняется путем глобального поиска в заранее заданном пространстве восстанавливаемых упругих параметров. Для этого используются такие алгоритмы, как метод Монте-Карло [5], генетический алгоритм [6], алгоритм имитации отжига [7], алгоритм ближайшего соседа [8], Grey Wolf Optimizer (GWO) [9], полносвязанные нейронные сети [10, 11]. Актуальная проблема методов глобальной оптимизации — требования к вычислительным ресурсам, необходимость настройки гиперпараметров и неустойчивость решения. Преимуществами использования нейронных сетей для решения обратных задач являются их устойчивость к случайному шуму, незначительные требования к вычислительным ресурсам и отсутствие необходимости дополнительной настройки параметров при использовании обученной нейронной сети. В статье представлен алгоритм метода SWI, включающий в себя использование двух типов нейронных сетей: автоэнкодер для извлечения и полносвязанная нейронная сеть для обращения дисперсионной кривой поверхностной волны. В следующих разделах представлено описание алгоритма SWI, подхода к генерации тренировочных данных, архитектуры используемых нейронных сетей,

результатов их обучения и тестирования на синтетических данных. Также приведен пример обработки реальных сейсморазведочных данных с помощью комплекса разработанных алгоритмов метода SWI и сделаны выводы.

РАЗРАБОТАНЫ АЛГОРИТМЫ ИЗВЛЕЧЕНИЯ ДИСПЕРСИОННЫХ КРИВЫХ И ИХ ИНВЕРСИИ НА ОСНОВЕ МЕТОДОВ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ, КОТОРЫЕ ПОЗВОЛЯЮТ АВТОМАТИЗИРОВАТЬ SWI С СУЩЕСТВЕННЫМ УСКОРЕНИЕМ ВСЕХ ЭТАПОВ, РЕШАЯ ПРОБЛЕМУ РУЧНОЙ ОБРАБОТКИ СЕЙСМИЧЕСКИХ ДАННЫХ.

ОПИСАНИЕ МЕТОДА АНАЛИЗА И ИНВЕРСИИ ПОВЕРХНОСТНЫХ ВОЛН

Обработка сейсморазведочных данных по разрабатываемому методу SWI включает в себя следующие основные этапы.

1. Предпроцессинг исходных данных.

На первом этапе обработки сейсмограммы общей точки возбуждения (ОТВ), полученные для профильной системы наблюдений, нарезаются в соответствии с пространственным окном заданного размера, называемого базой наблюдения. При этом отдельно обрабатываются правая (положительные удаления источник — приемник) и левая (отрицательные удаления) ветви сейсмограмм.

2. Спектральное преобразование сейсмограмм.

Каждая сейсмограмма трансформируется в область распределения амплитуд по фазовой скорости волны Релея и частоте ($V_R - f$ область или дисперсионное изображение) путем применения одного из алгоритмов спектрального анализа. Авторами используется собственный алгоритм SFK-преобразования, который основан на преобразовании Стоквелла и фильтрации сейсмограмм во временно-частотной области [12]. Использование такого подхода позволяет повысить устойчивость метода SWI за счет дополнительного автоматического усиления сигнала поверхностной волны на фоне регулярных и случайных помех.

3. Извлечение дисперсионных кривых.

Путем применения подготовленной (обученной) нейронной сети типа автоэнкодер (АЕ или autoencoder) дисперсионное изображение преобразуется в бинарную маску с выделением зоны распределения амплитуды

для фундаментальной моды. Дисперсионная кривая строится для набора полученных маской точек путем приближения кривой аппроксимации по методу наименьших квадратов (МНК).

4. Инверсия дисперсионных кривых.

Путем использования обученной полносвязанной нейронной сети (FCNN или fully-connected neural network) каждая извлеченная кривая обращается в одномерную (1D) гладкую скоростную модель S-волны.

5. Построение двумерных или трехмерных скоростных разрезов.

Результат инверсии относится к середине базы наблюдения, для которой была получена дисперсионная кривая. Построение двумерных (2D) или трехмерных (3D) скоростных разрезов осуществляется путем пространственной интерполяции восстановленных 1D-моделей.

ГЕНЕРАЦИЯ ТРЕНИРОВОЧНЫХ ДАННЫХ

В предположении горизонтально-слоистой упругой модели геологической среды зависимость фазовой скорости волны Релея от частоты, т.е. дисперсионная кривая, или $V_R(f)$, является решением дисперсионного уравнения [13]:

$$V_R(f) = F[V_S(z), V_P(z), \rho(z), z, f], \quad (1)$$

где f — временная частота, $V_S(z)$, $V_P(z)$, $\rho(z)$ — ступенчатые функции зависимости скорости S-волны, скорости P-волны и плотности от глубины z соответственно. Уравнение (1) является нелинейным и позволяет рассчитывать одновременно все существующие режимы (моды) дисперсионных кривых. В текущей работе рассматривается возможность извлечения и инверсии только фундаментальной (нулевой) моды поверхностной волны. Фазовая скорость волны Релея наиболее чувствительна к изменениям V_S и почти нечувствительна к V_P и ρ . Поэтому при решении прямой задачи используется соотношение для упругой однородной модели среды: $V_P = V_S \sqrt{2(1-\nu)/(1-2\nu)}$, где $\nu = 0,35$ — типичное для ВЧР значение коэффициента Пуассона. Значения плотности вычисляются из корреляционной зависимости: $\rho = 610 \cdot V_P^{0,18}$ (кг/м³).

Для формирования обучающей выборки из заранее заданных диапазонов равномерно перебираются значения V_S (в пределах от 200 до 1500 м/с) и мощностей слоев (в пределах от 1 до 100 м), рассчитываются V_P и ρ

и дисперсионные кривые V_R . Пример одной из моделей и соответствующая ей фундаментальная мода волны Релея представлены на **рис. 1**.

Входной слой FCNN формирует матрица, столбцы которой заполнены значениями V_R , f и $\lambda = V_R/f$. Выходом FCNN является гладкая модель V_S , которая не зависит от количества слоев. Гладкость достигается за счет интерполяции вектора V_S методом ближайшего соседа на равномерную сетку с шагом 0,5 м. Обучающая выборка для FCNN включает в себя по 20000 примеров двух-, трех- и четырехслойных скоростных моделей. При этом вектор частот, использующихся для расчета V_R , также генерируется в случайном диапазоне: минимальная частота варьировалась в пределах от 1 до 10 Гц, максимальная частота от 14 до 50 Гц. Такой подход симулирует поведение реальных данных, в которых наблюдаемый частотный диапазон зависит от фильтрационных свойств среды и характеристик сейсмического оборудования.

Для обучения сети АЕ необходимо подготовить набор спектральных изображений, соответствующих расчётным кривым. Для генерации волнового поля поверхностных волн использовался метод модального суммирования, основанный на вычислении собственных функций волны Релея и расчета функций Грина (спектрального представления сейсмической трассы для набегающей дельта-функции) для вертикального типа источника. Расчет сейсмограммы осуществляется

переводом функции Грина во временную область и сверткой с импульсом Рикера с частотой 30 Гц.

Обучающая выборка генерировалась для четырехслойной модели среды. Для каждой скоростной модели, которые равномерно выбираются из заданного диапазона, рассчитывается сейсмограмма ПВ со следующими параметрами: шаг между приемниками — 1 м, частота дискретизации — 1000 Гц, длина записи — 1 с. Затем с помощью SFK-преобразования рассчитывается дисперсионное изображение. Диапазон фазовых скоростей для построения дисперсионного изображения: от 0 до 1500 м/с, диапазон частот: от 5 до 50 Гц.

Для устойчивого извлечения дисперсионных кривых сеть АЕ применяется для бинаризации дисперсионного изображения с выделением области распределения амплитуды фундаментальной моды. Для этого каждому дисперсионному изображению соотносится бинарная маска, в которой целевая область распределения амплитуд заполняется единицами путем наложения истинной дисперсионной кривой. Пример рассчитанной сейсмограммы, соответствующее ей дисперсионное изображение и бинарная маска представлены на **рис. 2**. Таким образом, на входной слой АЕ подается одноканальное дисперсионное изображение, на выходной слой — двухканальное изображение соответствующей маски. Для ускорения обучения входные и выходные изображения преобразуются в изображения размером




Рис. 1. Пример из тренировочного набора данных FCNN: модели скорости и плотности (слева) и соответствующая ей дисперсионная кривая (справа). Составлено авторами

Fig. 1. Example from the FCNN training dataset: velocity and density models (left) and its corresponding dispersion curve (right). Compiled by the authors




Рис. 2. Пример из тренировочного набора данных АЕ: сейсмограмма поверхностной волны (слева), соответствующее ей дисперсионное изображение (в центре) и бинарная маска с выделением амплитуд дисперсионной кривой (справа). Составлено авторами

Fig. 2. Example from the AE training dataset: surface wave gather (left), its corresponding dispersion image (center), and a binary mask with amplitude extraction of the dispersion curve (right). Compiled by the authors

128x128 пикселей. Объем обучающей выборки — 3 000 дисперсионных изображений и соответствующих им бинарных масок.

ОПИСАНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ИЗВЛЕЧЕНИЯ ДИСПЕРСИОННЫХ КРИВЫХ

Обучение сети АЕ с использованием масок объектов сводится к решению задачи бинарной сегментации. На вход АЕ подается дисперсионное изображение (рис. 3, слева). Результатом работы АЕ является маска целевого сигнала (рис. 3, справа), заполненная нулями и единицами (1 — класс дисперсионная кривая; 0 — класс шум). Для повышения устойчивости работы нейронной сети была добавлена вспомогательная маска шума, получаемая в ходе

вычитания маски целевого сигнала из единичного изображения.

Используемая нейросетевая архитектура состоит из 29 слоёв двумерной свёртки (Conv2D), 4 слоёв понижения размерности (MaxPooling2D), 4 слоёв повышения размерности (UpSampling2D), 4 пропускных связей (skip-connection) [14]. В качестве функции активации на скрытых слоях используется функция усеченного линейного преобразования (ReLU или Rectified Linear Unit), на выходном слое — гиперболический тангенс (Tanh). В качестве функции невязки используется среднеквадратическая ошибка (MSE или mean squared error).

На этапе подготовки тренировочных данных применялась нормализация путем деления на максимум. Подготовленный набор тренировочных данных (30000 примеров) разбивается на обучающую и тестовую выборки




Рис. 3. Результат применения АЕ: пример входного изображения (слева) и восстановленной маски (справа). Пунктирной зеленой и оранжевой кривой нанесены извлеченная и истинная дисперсионная кривая соответственно. Составлено авторами

Fig. 3. Result of applying AE: example of the input image (left) and the reconstructed mask (right). The dotted green and orange curves plot the extracted and true dispersion curve, respectively. Compiled by the authors

в соотношении 50/50. Используемый оптимизатор — алгоритм Adam. Размер пакета (batch) при обучении — 64, размер валидационной выборки — 20 % (300 примеров), число эпох обучения — 50. Однако уже на 30-й эпохе функция невязки достигла своего минимума после гладкого убывания.

Контроль качества работы нейронной сети проводился путём сравнения извлечённых и истинных дисперсионных кривых. Процедура извлечения дисперсионных кривых из предсказанных масок состояла из двух этапов: 1) кластеризация изображения с целью выделения облака точек, соответствующего классу фундаментальной моды, и удаления выбросов; 2) кусочно-линейная аппроксимация. На **рис. 4** представлено распределение средней абсолютной ошибки в процентах (MAPE или mean absolute percentage error) между извлечёнными и истинными дисперсионными кривыми для всего набора тестовых данных. Результаты тестирования показывают высокую успешность обучения АЕ и низкие значения ошибок извлечения дисперсионных кривых на синтетических данных: математическое ожидание распределения MAPE 0,95 %, стандартное отклонение 0,45 %.

ОПИСАНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ИНВЕРСИИ ДИСПЕРСИОННЫХ КРИВЫХ

Обучение сети FCNN для решения обратной задачи сводится к задаче регрессии и аппроксимации обратного оператора. Входной слой FCNN формирует матрица размером 50×3 , столбцы которой заполнены значениями $V_R f$ и λ . Выход FCNN — вектор V_S размером 50×1 . Подготовленный набор тренировочных данных (30000 примеров) разбивается на обучающую и тестовую выборки в соотношении 50/50. Перед обучением набор входных и выходных тренировочных данных проходит через процедуру стандартизации, т.е. преобразования признаков для получения среднего значения 0 и стандартного отклонения 1. Масштабирующие коэффициенты сохраняются для их последующего применения к тестовым и реальным наборам данных. Архитектура используемой полносвязной нейронной сети FCNN моделирует поведение автоэнкодера сжимая и разжимая пространство признаков в соответствии со следующими размерами скрытых слоев нейронов, начиная с первого: 256, 128, 64, 32, 64, 128, 256. На каждом внутреннем слое после вычисления весов последовательно применяется пакетная нормализация

(batch-normalization), активация функцией ReLU и исключение 0,5 % весов (dropout). Функция активации на выходном слое — Tanh. Веса FCNN настраиваются путем минимизации функции невязки (loss-функции):

$$MAE(\hat{F}(\mathbf{W}, V_R, f, \lambda) - V_S) \rightarrow \min,$$

где MAE — средняя абсолютная ошибка, $\mathbf{W}$ — подобранные веса, $\hat{F}$ — обратный оператор FCNN, т.е. применение весов к входному слою. Используемый оптимизатор — алгоритм Adam с адаптивным вычислением скорости обучения. Размер пакета (batch) при обучении — 128, размер валидационной выборки — 20 % (3000 примеров), число эпох обучения — 100. В ходе обучения функционалы невязки тренировочной и валидационной выборки гладко уменьшаются более чем в 100 раз, переобучения не происходит. На **рис. 5** представлен пример применения обученной FCNN к дисперсионной кривой из тестового набора данных для скоростной модели с ошибкой MAPE 5 % (средняя ошибка для всего набора тестовых данных). Полное распределение MAPE между истинными и восстановленными скоростными моделями из тестового набора данных представлено на **рис. 6**. Низкие значения математического ожидания (5 %) и стандартного отклонения (4 %) показывают высокую успешность обучения FCNN.

ОБРАБОТКА РЕАЛЬНЫХ ДАННЫХ НАЗЕМНОЙ СЕЙСМОРАЗВЕДКИ МЕТОДОМ SWI

Используемые для апробации разработанных алгоритмов реальные данные зарегистрированы в ходе наземных сейсморазведочных работ на нефтегазовом




Рис. 4. Результат применения АЕ: распределение MAPE между извлеченными и истинными дисперсионными кривыми для тестового набора данных.

Составлено авторами

Fig. 4. Result of applying AE: MAPE distribution between extracted and true variance curves for the test dataset. Compiled by the authors




Рис. 5. Результат применения FCNN: пример истинной и восстановленной скоростной модели (слева) и истинной и восстановленной (рассчитанная по восстановленной скоростной модели) дисперсионной кривой (справа).

Составлено авторами

Fig. 5. Result of applying FCNN: example of true and reconstructed velocity model (left) and true and reconstructed (calculated from the reconstructed velocity model) dispersion curve (right). Compiled by the authors

месторождении в Ханты-Мансийском автономном округе, Западная Сибирь, Россия. Данные содержат записи около 18 000 сейсмограмм ОТВ для линейных сейсмических профилей общей протяженностью почти 900 км (всего профилей — 21). Основные технические параметры системы наблюдения: шаг между приемниками 25 м, шаг между источниками 50 м, длина записи 6 с, частота дискретизации 500 Гц, используемый тип источника — взрывы в скважинах глубиной около 15 м.

Для обработки данных методом SWI и построения модели ВЧР данные последовательно проходят через все этапы, описанные в первой части статьи (пред-процессинг, спектральное преобразование, извлечение дисперсионных кривых,

инверсия и пространственная интерполяция). Выбранная длина базы наблюдения — 800 м. Это значение выбрано в качестве компромисса между спектральным разрешением данных и латеральным разрешением модели ВЧР.

На **рис. 7** представлен пример рассчитанного дисперсионного изображения и предсказанной с помощью АЕ маски распределения амплитуд фундаментальной моды поверхностной волны. Всего автоматически извлечено 35 010 дисперсионных кривых фазовых скоростей (по 17 505 кривых для левых и правых ветвей сейсмограмм). Фундаментальная мода поверхностной волны находится в диапазоне от 1 до 10 Гц, фазовые скорости поверхностных волн изменяются в пределах от 100 до 1500 м/с.

Набор полученных дисперсионных кривых обращается в 1D-модели скорости S-волны путем применения обученной FCNN. При обработке данных не учитывается форма рельефа (в пределах базы наблюдения рельеф считается плоским). Каждая 1D-модель относится к середине базы наблюдения и к абсолютной отметке рельефа в этой точке. С помощью пространственной интерполяции строится 2D скоростная модель ВЧР.

На **рис. 8** представлен пример восстановленной 2D-модели ВЧР для одного из профилей (всего 2D-моделей — 21). Восстановленные модели скоростей S-волны в большинстве своем характеризуется плоско-горизонтальной слоистой структурой с небольшими флуктуациями рельефа границ. До восстановленной глубины в 100 м преимущественно




Рис. 6. Результат применения FCNN: распределение MAPE между истинными и восстановленными скоростными моделями из тестового набора данных. Составлено авторами

Fig. 6. Result of applying FCNN: MAPE distribution between true and reconstructed velocity models from the test dataset. Compiled by the authors




Рис. 7. Пример дисперсионного изображения реальной сейсмограммы ОТВ (слева) и предсказанной с помощью АЕ бинарной маски (справа). Зеленой пунктирной линией нанесена дисперсионная кривая, полученная аппроксимацией полученных точек. Составлено авторами

Fig. 7. Example of the dispersion image of the real shot gather (left) and the binary mask predicted with AE (right). The green dashed line shows the dispersion curve obtained by approximation of the obtained points. Compiled by the authors

выделяются три слоя со средними скоростями S-волны 200, 600, 1400 м/с и толщинами 20 и 40 м. Полученные результаты согласуются с результатами других методов и со скважинными данными. Таким образом, разработанные алгоритмы успешно демонстрируют свою эффективность при обработке реальных данных сейсморазведки. А результаты подтверждают перспективность использования нейронных сетей для автоматизации и ускорения анализа и инверсии поверхностных волн в сейсморазведке.

ВЫВОДЫ

В работе представлена новая реализация метода SWI, основанная на глубоком машинном обучении, что позволяет автоматизировать и ускорить построение скоростной модели верхней части геологического разреза.

Разработаны две архитектуры нейронных сетей: сверточная модель типа автоэнкодер для извлечения дисперсионных кривых и полносвязанная нейронная сеть для их инверсии. Результаты показали высокую точность автоматического извлечения и инверсии дисперсионных кривых поверхностных волн на тестовом наборе данных. Средняя абсолютная процентная ошибка составила 1 % для извлеченных кривых и 5 % для восстановленных скоростных моделей. Разработанные алгоритмы были успешно применены для построения модели ВЧР по реальным сейсморазведочным данным нефтегазового месторождения в Западной Сибири.

Предложенный комплекс алгоритмов эффективно автоматизирует и ускоряет метод SWI, делая его применимым для обработки больших объемов сейсморазведочных данных.




Рис. 8. Пример скоростной модели ВЧР, построенной в результате обработки данных автоматизированным методом SWI. Составлено авторами

Список литературы

1. Yablokov A.V., Serdyukov A.S., Loginov G.N., Baranov V.D. An artificial neural network approach for the inversion of surface wave dispersion curves // *Geophysical Prospecting*. 2021, vol. 69, no. 7, pp. 1405–1432.
2. Cheng F. et al. Watching the cryosphere thaw: Seismic monitoring of permafrost degradation using distributed acoustic sensing during a controlled heating experiment // *Geophysical Research Letters*. 2022, vol. 49, no. 10, pp. e2021GL097195.
3. Bai J., Yilmaz O. Model-based surface wave analysis and attenuation // 80th EAGE Conference and Exhibition 2018. — European Association of Geoscientists & Engineers. 2018, no. 1, pp. 1–5.
4. Askari R., Ferguson R.J., Isaac J.H., Hejazi, S.H. Estimation of S-wave static corrections using CMP cross-correlation of surface waves // *Journal of Applied Geophysics*. 2015, vol. 121, pp. 42–53.
5. Socco L.V., Boiero D. Improved Monte Carlo inversion of surface wave data // *Geophysical Prospecting*. 2008, vol. 56, no. 3, pp. 357–371.
6. Dal Moro G., Pipan M., Gabrielli P. Rayleigh wave dispersion curve inversion via genetic algorithms and marginal posterior probability density estimation // *J. Appl. Geophys.* 2007, vol. 61, no. 1, pp. 39–55.
7. Pei D., Louie J.N., Pullammanappallil S.K. Application of simulated annealing inversion on high-frequency fundamental-mode Rayleigh wave dispersion curves // *Geophysics*. 2007, vol. 72, no. 5, pp. R77–R85.
8. Cox B.R., Teague D.P. Layering ratios: a systematic approach to the inversion of surface wave data in the absence of a priori information // *Geophysical Journal International*. 2016, vol. 207, no. 1, pp. 422–438.
9. Song X., Tang L., Zhao S., Zhang X., Li L., Huang J., Cai W. Grey Wolf Optimizer for parameter estimation in surface waves // *Soil Dynamics and Earthquake Engineering*. 2015, vol. 75, pp. 147–157.
10. Aleardi M., Stucchi E. A hybrid residual neural network — Monte Carlo approach to invert surface wave dispersion data // *Near Surface Geophysics*. 2021, no. 4, pp. 397–414.
11. Yablokov A., Lugovtsova Y., Serdyukov A. Uncertainty quantification of multimodal surface wave inversion using artificial neural networks // *Geophysics*. 2023, vol. 88, no. 2, pp. KS1–KS11.
12. Serdyukov A.S., Yablokov A.V., Duchkov A.A., Azarov A.A., Baranov V.D. Slant f-k transform of multichannel seismic surface wave data // *Geophysics*. 2019, vol. 84, no. 1, pp. A19–A24.
13. Lai C.G., Foti S., Rix G.J. Propagation of data uncertainty in surface wave inversion // *Journal of Environmental & Engineering Geophysics*. 2005, vol. 10, no. 2, pp. 219–228.
14. Камашев А.М., Дучков А.А. Применение машинного обучения для адаптивного вычитания кратных отраженных волн // *Геофизические технологии*. — 2023. — № 1. — С. 54–65.

References

1. Yablokov A.V., Serdyukov A.S., Loginov G.N., Baranov V.D. An artificial neural network approach for the inversion of surface wave dispersion curves // *Geophysical Prospecting*. 2021, vol. 69, no. 7, pp. 1405–1432.
2. Cheng F. et al. Watching the cryosphere thaw: Seismic monitoring of permafrost degradation using distributed acoustic sensing during a controlled heating experiment // *Geophysical Research Letters*. 2022, vol. 49, no. 10, pp. e2021GL097195.
3. Bai J., Yilmaz O. Model-based surface wave analysis and attenuation // 80th EAGE Conference and Exhibition 2018. — European Association of Geoscientists & Engineers. 2018, no. 1, pp. 1–5.
4. Askari R., Ferguson R.J., Isaac J.H., Hejazi, S.H. Estimation of S-wave static corrections using CMP cross-correlation of surface waves // *Journal of Applied Geophysics*. 2015, vol. 121, pp. 42–53.
5. Socco L.V., Boiero D. Improved Monte Carlo inversion of surface wave data // *Geophysical Prospecting*. 2008, vol. 56, no. 3, pp. 357–371.
6. Dal Moro G., Pipan M., Gabrielli P. Rayleigh wave dispersion curve inversion via genetic algorithms and marginal posterior probability density estimation // *J. Appl. Geophys.* 2007, vol. 61, no. 1, pp. 39–55.
7. Pei D., Louie J.N., Pullammanappallil S.K. Application of simulated annealing inversion on high-frequency fundamental-mode Rayleigh wave dispersion curves // *Geophysics*. 2007, vol. 72, no. 5, pp. R77–R85.
8. Cox B.R., Teague D.P. Layering ratios: a systematic approach to the inversion of surface wave data in the absence of a priori information // *Geophysical Journal International*. 2016, vol. 207, no. 1, pp. 422–438.
9. Song X., Tang L., Zhao S., Zhang X., Li L., Huang J., Cai W. Grey Wolf Optimizer for parameter estimation in surface waves // *Soil Dynamics and Earthquake Engineering*. 2015, vol. 75, pp. 147–157.
10. Aleardi M., Stucchi E. A hybrid residual neural network—Monte Carlo approach to invert surface wave dispersion data // *Near Surface Geophysics*. 2021, no. 4, pp. 397–414.
11. Yablokov A., Lugovtsova Y., Serdyukov A. Uncertainty quantification of multimodal surface wave inversion using artificial neural networks // *Geophysics*. 2023, vol. 88, no. 2, pp. KS1–KS11.
12. Serdyukov A.S., Yablokov A.V., Duchkov A.A., Azarov A.A., Baranov V.D. et al. Slant f-k transform of multichannel seismic surface wave data // *Geophysics*. 2019, vol. 84, no. 1, pp. A19–A24.
13. Lai C.G., Foti S., Rix G.J. Propagation of data uncertainty in surface wave inversion // *Journal of Environmental & Engineering Geophysics*. 2005, vol. 10, no. 2, pp. 219–228.
14. Kamashev A.M., Duchkov A.A. Application of machine learning for adaptive subtraction of multiple reflected waves // *Geofizicheskiye tekhnologii*. 2023, no. 1, pp. 54–65.

ВКЛАД АВТОРОВ / AUTHOR CONTRIBUTIONS

А.В. Яблоков — разработка и реализация алгоритмов, разработка концепции и подготовка статьи, окончательное утверждение публикуемой версии статьи и согласен принять на себя ответственность за все аспекты работы.

А.М. Камашев — сопровождение разработки алгоритмов и анализ результатов их применения.

М.В. Моисеев — апробация алгоритмов на реальных данных, анализ результатов и подготовка иллюстраций.

Alexandr V. Yablokov — development and implementation of algorithms, conceptualisation and preparation of the paper, final approval of the published version of the paper and agrees to take responsibility for all aspects of the paper.

Aleksandr M. Kamashev — supporting the development of algorithms and analysing the results of their application.

Mikhail V. Moiseev — testing algorithms on real data, analysing results and preparing illustrations.

СВЕДЕНИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Александр Викторович Яблоков* — кандидат физико-математических наук, старший научный сотрудник, Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН; старший научный сотрудник, Новосибирский государственный университет; научный сотрудник, Институт физики Земли имени О.Ю. Шмидта РАН 630090, Россия, г. Новосибирск, пр-т Академика Коптюга, д. 3.
630090, Россия, г. Новосибирск, ул. Пирогова, д. 1. 123242, Россия, г. Москва, Б. Грузинская ул., д. 10, стр. 1.
e-mail: YablokovAV@ipgg.sbras.ru
SPIN-код: 2931-3505
ORCID: <https://orcid.org/0000-0002-3251-0289>
Researcher ID: N-9685-2017
Scopus ID: 56950559800

Александр Максимович Камашев — младший научный сотрудник, Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН; младший научный сотрудник, Новосибирский государственный университет
SPIN-код: 4496-2688
ORCID: <https://orcid.org/0000-0001-8368-1144>
Researcher ID: rid45346

Михаил Викторович Моисеев — инженер, Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН; лаборант, Новосибирский государственный университет
ORCID: <https://orcid.org/0009-0004-9573-6295>
Researcher ID: LGZ-9542-2024
Scopus ID: 59132424000

Alexandr V. Yablokov* — Cand. Sci. (Phys.-Math.), Senior Researcher, Trofimuk Institute of Petroleum Geology and Geophysics Siberian Branch of the Russian Academy of Sciences; Senior Researcher, Novosibirsk State University; Researcher, Schmidt Institute of Physics of the Earth, Russian Academy of Sciences
3, Akademika Koptuyuga Avenue, 630090, Novosibirsk, Russia.
1, Pirogova str., 630090, Novosibirsk, Russia.
10, p. 1., B. Gruzinskaya str., 123242, Moscow, Russia.
e-mail: YablokovAV@ipgg.sbras.ru
SPIN-code: 2931-3505
ORCID: <https://orcid.org/0000-0002-3251-0289>
Researcher ID: N-9685-2017
Scopus ID: 56950559800

Aleksandr M. Kamashev — Junior Researcher, Trofimuk Institute of Petroleum Geology and Geophysics Siberian Branch of the Russian Academy of Sciences; Junior Researcher, Novosibirsk State University
SPIN-code: 4496-2688
ORCID: <https://orcid.org/0000-0001-8368-1144>
Researcher ID: rid45346

Mikhail V. Moiseev — Engineer, Trofimuk Institute of Petroleum Geology and Geophysics Siberian Branch of the Russian Academy of Sciences; Laboratory Assistant, Novosibirsk State University
ORCID: <https://orcid.org/0009-0004-9573-6295>
Researcher ID: LGZ-9542-2024
Scopus ID: 59132424000

* Автор, ответственный за переписку / Corresponding author