

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

Разработка нейросетевого алгоритма инверсии дисперсионного изображения поверхностной волны

¹ Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,
г. Новосибирск, Российская Федерация

² Институт горного дела им. Н.А. Чинакала СО РАН, г. Новосибирск, Российская Федерация

³ Новосибирский государственный университет, г. Новосибирск, Российская Федерация

*e-mail: m.moiseev@g.nsu.ru

Аннотация. Методы, основанные на анализе поверхностных волн, позволяют восстановить распределение скоростей поперечных (S) волн. Построение скоростной модели осуществляется в несколько этапов: спектральный анализ и пикирование дисперсионных кривых, инверсия дисперсионных кривых. Процесс пикирования кривых субъективен из-за этого результаты инверсии могут сильно отличаться. Данное исследование направлено на автоматизацию процесса инверсии. В работе представлен подход инверсии дисперсионного изображения поверхностной волны на основе нейронной сети EfficientNet-B7. Набор обучающих данных был создан путем моделирования сейсмограмм поверхностной волны с использованием метода модального суммирования. Обученная нейронная сеть показывает высокую точность восстановления скоростного разреза на синтетических данных.

Ключевые слова: MASW, инверсия, EfficientNet-B7, инженерная сейсморазведка

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

Development of a neural network algorithm for inversion of the dispersion image of a surface wave

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

² Chinakal Institute of Mining SB RAS, Novosibirsk, Russian Federation

³ Novosibirsk State University, Novosibirsk, Russian Federation

*e-mail: m.moiseev@g.nsu.ru

Abstract. Methods based on the analysis of surface waves allow us to reconstruct the velocity distribution of transverse (S) waves. The construction of the velocity model is carried out in several stages: spectral analysis and diving of dispersion curves, inversion of dispersion curves. The process of diving curves is subjective because of this, the results of the inversion can vary greatly. This study is aimed at automating the inversion process. The paper presents an approach to inversion of the dispersion image of a surface wave based on the EfficientNet-B7 neural network. The training data set was created by modeling surface wave seismograms using the modal summation method. The trained neural network shows high accuracy in reconstructing the high-speed section on synthetic data.

Keywords: MASW, inverse problem, EfficientNet-B7, engineering seismic

Введение

Для решения задач инженерной сейсморазведки чаще всего применяют методы, основанные на преломленных (МПВ) или поверхностных волнах (ПВ). Методы, основанные на анализе ПВ, используются для построения скоростной модели верхней части разреза грунтов [2], сейсмического мониторинга [7], шумоподавления [5] и др. Наиболее распространенным является метод многоканального анализа ПВ (MASW). Данный метод существенно дополняет МПВ и сейсмическую томографию, т.к. обладает рядом преимуществ: помехоустойчивость (высокое соотношение сигнал/шум), отработанная методика получения и обработки данных, высокая информативность, отсутствие физических ограничений для определения слоев с инверсной скоростью. Обработка данных методом MASW делится на три этапа – препроцессинг данных, спектральный анализ и инверсия.

На этапе препроцессинга осуществляется фильтрация данных. На этапе спектрального анализа рассчитываются дисперсионные изображения и пикируются дисперсионные кривые ПВ. Чаще всего пикирование дисперсионных кривых выполняется в ручном или полуавтоматическом режиме. Автоматизация данного процесса осложнена наличием шумов в данных, которые приводят к возникновению ложных спектральных максимумов. Инверсия дисперсионных кривых является сложной и неоднозначной задачей. Процесс инверсии итеративный и зависит от начальной модели, которая определяется по априорным данным, метода инверсии и функционала невязки.

Альтернативным подходом инверсии поверхностных волн является обращение полного дисперсионного изображения. Данный подход позволяет автоматизировать процесс инверсии, исключая этап пикирования ПВ и использовать для обращения совокупность мод, что понижает неоднозначность восстанавливаемой модели. Инверсия дисперсионного изображения является вычислительно сложной задачей из-за необходимости подбора большого количества параметров [1]. В последние годы для эффективного решения обратной задачи активно при-

меняются нейронные сети [3, 4]. Это позволяет полностью автоматизировать процесс обработки данных и сократить временные затраты на решение обратной задачи MASW.

В данном исследовании инверсию дисперсионных изображений предлагается делать на основе архитектуры EfficientNet-B7 [8]. Выбор данной архитектуры обусловлен тем, что при меньшем наборе параметров данная модель является лучшей с точки зрения эффективности и точности. Сравнение производилось на наборе данных ImageNet (рис. 1).

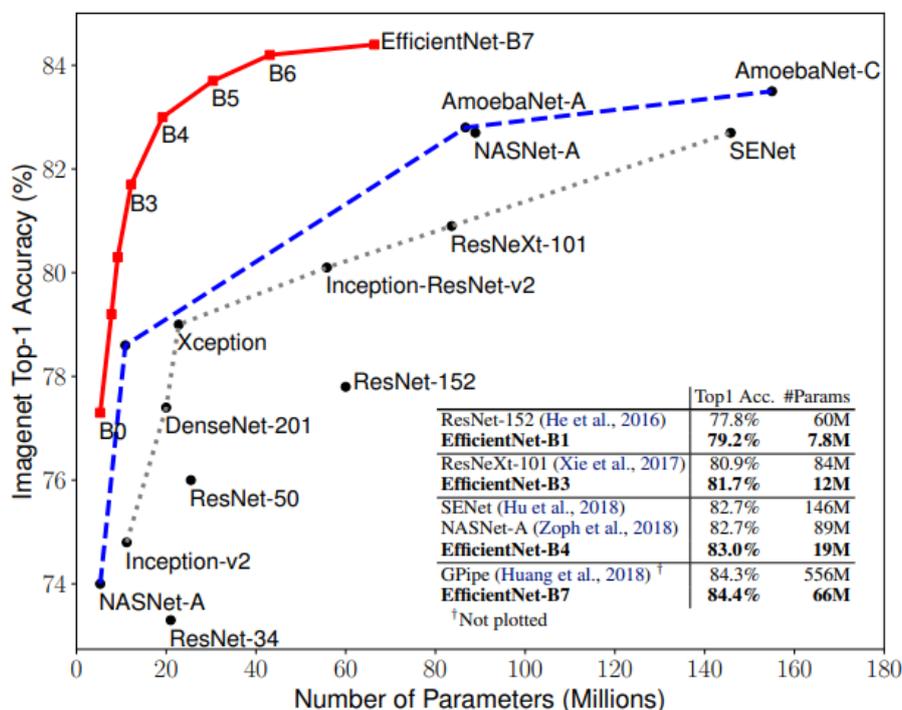


Рис. 1. Сопоставление размеров моделей и точности предсказания на данных ImageNet [8]

Создание обучающей выборки и обучение модели

Генерация набора обучающих данных является важным этапом при обучении любой модели машинного обучения. В данном исследовании нейронная сеть обучается генерировать скоростное распределение поперечной (S) волны с глубиной по спектральному изображению ПВ. Для генерации волнового поля ПВ использовался метод модального суммирования (modal summation). Модуль был

реализован на основе алгоритмов программного пакета COMPUTER PROGRAMS IN SEISMOLOGY (CPS) с открытым исходным кодом. Расчет поля ПВ осуществляется на основе вычисления фазовых скоростей и собственных функций волны Релея методом Томасена-Хаскелла для последующего расчета функций Грина заданного типа источника (спектрального представления записи каждого сейсмоприёмника для набегающей дельта-функции). Сейсмограмма ПВ рассчитывается переводом функции Грина во временную область и сверткой с сигналом в источнике.

Обучающая выборка генерировалась для трехслойной модели среды, диапазоны распределения S-волны (V_s) и мощности (h) по слоям представлены в табл. 1. Скорость продольной волны определяется по формуле $V_p = 2 * V_s$, плотность $\rho = 0.61 * V_p^{0.18} * 1000$. Для каждой модели рассчитывается сейсмограмма ПВ со следующими параметрами: шаг между приемниками – 1 м, длина базы наблюдения – 100 м, частота дискретизации – 1000 Гц, длина записи – 1 с. Дисперсионные изображения рассчитываются с помощью SFK-преобразования [6]. Скорости на дисперсионном изображении от 0 до 1500 м/с, частоты от 0 до 100 Гц. На вход нейронной сети подаются одноканальные изображения размером 128×128 после преобразования масштаба (рис. 2, слева). Для того, чтобы выходом нейронной сети была гладкая модель, которая не зависит от количества слоев, слоистая модель V_s представляется в виде вектора интерполированных значений на равномерной сетке с фиксированным шагом – 0.1 м (рис. 2, справа). Было сгенерировано 20000 уникальных моделей, дополнительно данные были аугментированы и их число выросло до 200000.

Таблица 1

Распределение скоростей и мощностей слоев

Номер слоя	V_s , м/с	h , м
1	150-250	2-6
2	300-900	1-14
3	700-1200	∞

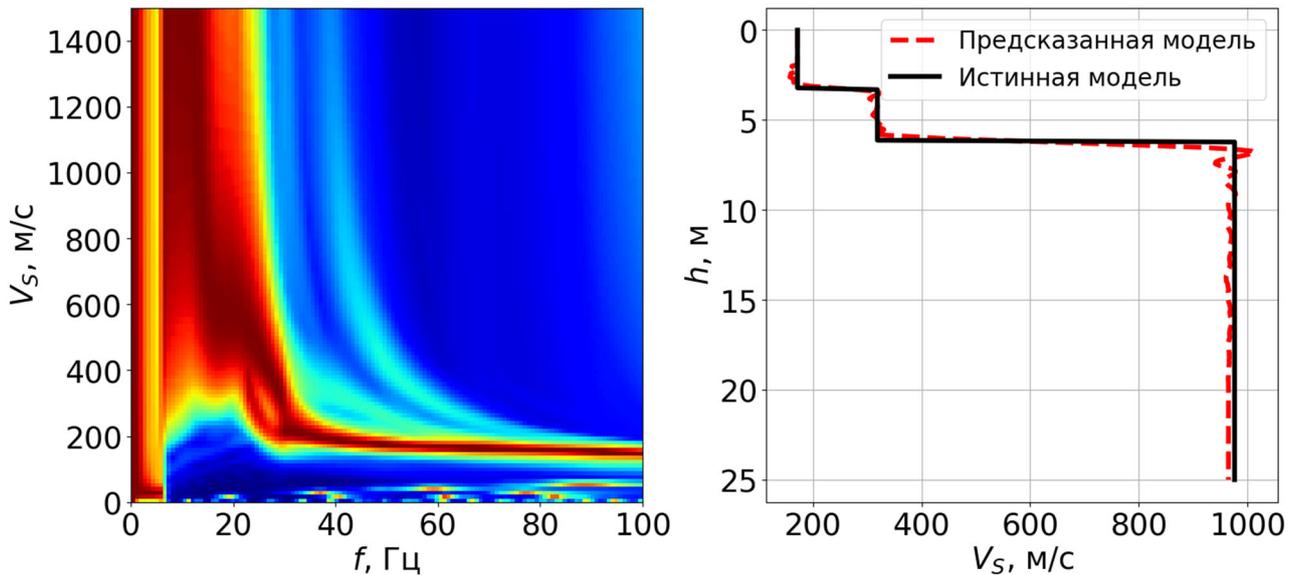


Рис. 2. Слева – пример дисперсионного изображения из обучающей выборки, справа – соответствующая истинная и предсказанная скоростная модель

Архитектура нейронной сети основана на модели EfficientNet-B7. Размер полносвязного слоя сети был изменен под размер вектора V_s . В качестве функции потерь используется нормализованная среднеквадратичная ошибка (NMSE), метод оптимизации при обучении – «Adam». Процесс обучения составляет 100 эпох. Шаг обучения изначально выбирался равным 0.001 и уменьшался каждые 10 эпох в два раза. Уменьшающиеся на каждой эпохе значения NMSE тренировочной и валидационной выборки показывают устойчивую сходимость процесса обучения (рис. 3, слева). Тестирование выполнялось на 3600 изображениях, не участвующих при обучении. Распределение средней процентной ошибки (MAPE) восстановления V_s на тестовой выборке представлено на рис. 3, справа. Медианное значение распределения MAPE составило около 3%. Расчёты проводились на видеокарте MSI GeForce RTX 4080, обучение занимает около 8 часов.

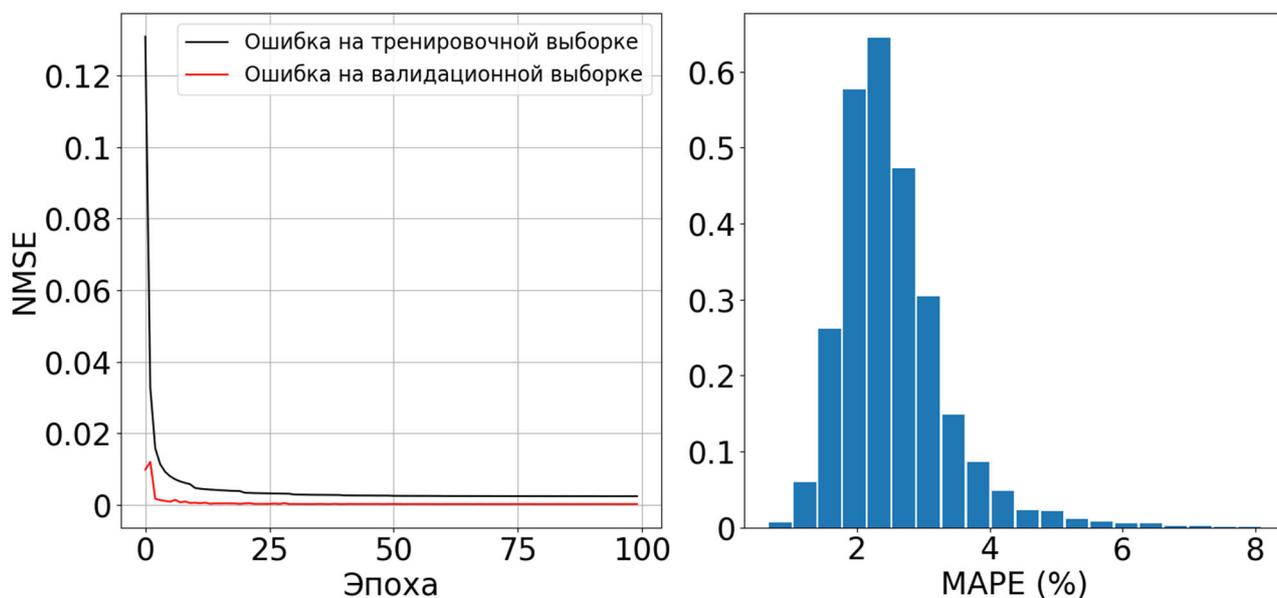


Рис. 3. Слева – кривые обучения, справа – гистограмма распределения ошибки (MAPE)

Результаты синтетических экспериментов

Апробация обученной нейронной сети проводилась на двух моделях: горизонтально-слоистой и модели талика. Данные были рассчитаны численным моделированием полного сейсмического поля. Результат инверсии модели горизонтально-слоистой среды представлен на рис. 4. Пунктиром показаны истинные положения границ. Визуальный анализ показывает, что нейронная сеть восстанавливает скоростное распределение с высокой точностью, однако положение границ варьируются относительно истинного положения.

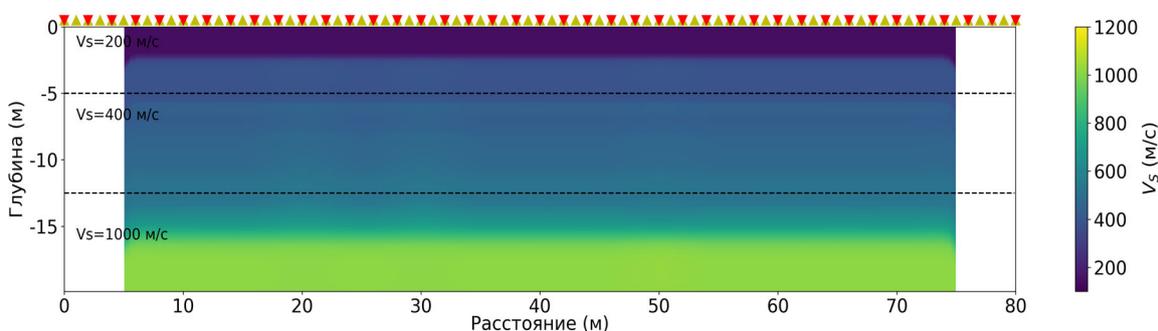


Рис. 4. Сопоставление истинной (пунктиром) и восстановленной модели горизонтально-слоистой среды

Инверсия модели талика представлена на рис. 5. Данное представление скоростной модели может описывать локальное оттаивание многолетнемерзлых грунтов. Точность восстановления скоростей по-прежнему высокая, однако границы области низких скоростей, предсказанные нейронной сетью, значительно отличаются от истинных границ.

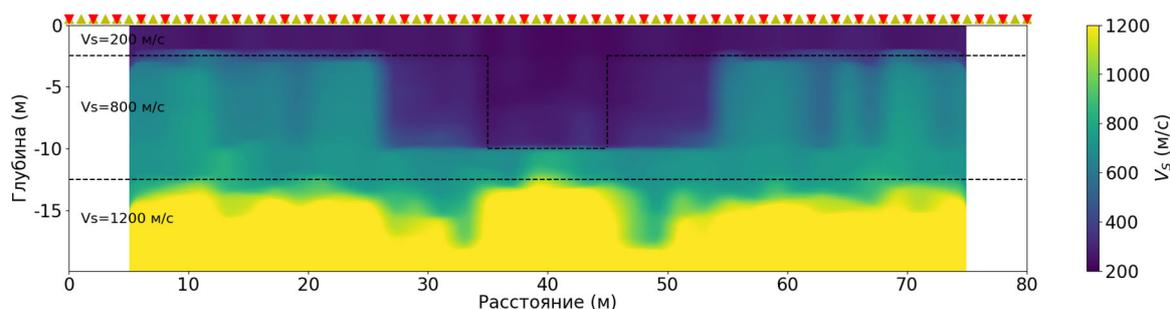


Рис. 5. Сопоставление истинной (пунктиром) и восстановленной модели талика

Заключение

В данном исследовании предложен подход к инверсии дисперсионных изображений поверхностной волны на основе сверхточной нейронной сети EfficientNet-B7. Восстанавливаемая модель скорости поперечной волны гладкая и не имеет ограничений на количество слоев. Обученная нейронная сеть была протестирована на синтетических данных. Визуальный анализ показал высокое качество восстановления скоростей слоев и удовлетворительное качество восстановления мощностей. Предложенный подход может применяться для инверсии поверхностной волны.

Благодарности

Исследование выполнено за счет совместного гранта Российского научного фонда и Правительства Новосибирской области № 23-27-10042, <https://rscf.ru/project/23-27-10042/>.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Ryden N., Park C. B. Fast simulated annealing inversion of surface waves on pavement using phase-velocity spectra // *Geophysics*. – 2006. – Vol. 71. – № 4. – P. R49-R58.
2. Xia J., Miller R. D., Park C. B. Estimation of near-surface shear-wave velocity by inversion of Rayleigh wave // *Geophysics* – 1999. – Vol. 64. – № 3. – P. 691-700.

3. Yablokov A., Lugovtsova Y., Serdyukov A. Uncertainty quantification of multimodal surface wave inversion using artificial neural networks // *Geophysics*. – 2023. – Vol. 88. – № 2. – P. KS1-KS11.
4. Aleardi M., Stucchi E. A hybrid residual neural network–Monte Carlo approach to invert surface wave dispersion data // *Near Surface Geophysics*. – 2021. – Vol. 19. – № 4. – P. 397-414.
5. Bai J., Yilmaz O. Model-based surface wave analysis and attenuation // *80th EAGE Conference and Exhibition 2018*. – European Association of Geoscientists & Engineers, 2018. – T. 2018. – № 1. – P. 1-5.
6. 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. – № 1. – P. A19-A24.
7. 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. – № 10. – P. e2021GL097195.
8. Tan M., Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks // *International conference on machine learning*. – PMLR, 2019. – P. 6105-6114.

© *М. В. Мусеев, А. В. Яблоков, 2024*