



ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ, УМЕНЬШАЮЩАЯ ЧИСЛЕННУЮ ДИСПЕРСИЮ, ДЛЯ ПОСТОБРАБОТКИ РЕЗУЛЬТАТОВ СЕЙСМИЧЕСКОГО МОДЕЛИРОВАНИЯ

К.А. Гадильшина, В.В. Лисица, Д.М. Вишнеvский, К.Г. Гадильшин

*Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,
630090, Новосибирск, просп. Акад. Коптюга, 3, Россия,
e-mail: LisitsaVV@ipgg.sbras.ru*

В работе описан новый подход к сейсмическому моделированию, сочетающий традиционный конечно-разностный метод с глубоким обучением. На первом шаге генерируется обучающий набор данных, рассчитанный для ограниченного числа источников. Этот набор вычисляется путем конечно-разностного моделирования на мелкой пространственно-временной сетке. На втором этапе рассчитываются сейсмограммы для всей системы наблюдения, но с использованием грубой расчетной сетки. На третьем, заключительном этапе происходит обучение искусственной нейронной сети, уменьшающей численную дисперсию, и ее применение ко всему набору данных. На тестовом материале проверена работоспособность такого подхода в задаче подавления численной дисперсии и продемонстрировано десятикратное ускорение расчетов сейсмических волновых полей.

Сейсмическое моделирование, численная дисперсия, глубокое обучение

DEEP NEURAL NETWORK REDUCING NUMERICAL DISPERSION FOR POST-PROCESSING OF SEISMIC MODELING RESULTS

K.A. Gadylshina, V.V. Lisitsa, D.M. Vishnevsky, K.G. Gadylshin

*Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, Koptuyug Ave., 3, Novosibirsk, 630090, Russia,
e-mail: LisitsaVV@ipgg.sbras.ru*

The article describes a new approach to seismic modeling that combines calculations using traditional finite difference methods with the deep learning tools. Seismograms for the training data set are calculated using a finite difference scheme with high-quality spatial and temporal discretization. A numerical dispersion mitigation neural network is trained on the training dataset and applied to inaccurate seismograms calculated on a raw grid with a large spatial spacing. The paper presents a demonstration of this approach for 2D model; it is showing a tenfold acceleration of seismic modeling.

Seismic modelling, numerical dispersion, deep learning

ВВЕДЕНИЕ

Численное моделирование сейсмических волновых полей является самой ресурсоемкой частью специальных методов обработки сейсмических данных, таких как миграция в обратном времени и метод обращения полного волнового поля [Virieux et al., 2009, 2011]. В задаче сейсмического моделирования обычно решаются уравнения линейной динамической теории упругости, поэтому для получения численного решения высокой точности необходимо проводить расчеты на мелкой вычислительной сетке. Чем меньше шаг по сетке, тем более точным будет численное решение. Вследствие чего сейсмическое

моделирование – это всегда поиск компромисса между точностью полученного решения и экономией вычислительных ресурсов.

Теоретически максимально возможный шаг дискретизации определяется частотой Найквиста, что диктует необходимость при построении расчетной сетки задавать минимум два узла на длину волны. Однако частота Найквиста определяется для аппроксимации конкретного вейвлета и не учитывает численную дисперсию, которая возникает из-за аппроксимации пространственных производных в волновом уравнении. В задаче сейсмического моделирования обычно используют дискретизацию, включающую от четырех до десяти точек на минимальную длину волны. Конечно-разностный метод является самым простым в реализации и наиболее часто используемым численным методом сейсмического моделирования. Самыми распространенными конечно-разностными методами решения уравнений линейной динамической теории упругости в двумерной постановке является стандартная схема на сдвинутых сетках [Virieux, 1986] и разновидность этой схемы, учитывающая аппроксимацию более высокого порядка по пространству [Levander, 1988].

Известным способом уменьшения численной дисперсии в конечно-разностном подходе является использование так называемых схем, подавляющих дисперсию. Идея этого подхода заключается в использовании больших шаблонов для аппроксимации пространственных производных со вторым порядком, но с избыточным числом точек (или степеней свободы) на доминирующую длину волны – порядка трех-пяти точек [Liu, Sen, 2009; Chen, 2014; Liu, 2014; Tan, Huang, 2014]. Однако такие схемы применимы для скалярного волнового уравнения, и их сложно обобщить на случай упругой среды.

В последние годы методы глубокого обучения нашли широкое применение в геофизических приложениях [Yu, Ma., 2021]. Глубокие нейронные сети эффективно применяются в задачах шумоподавления [Zhu et al., 2019; Yu et al., 2019] и в таких трудно формализуемых задачах, как обнаружение разломов или сейсмическая интерпретация [Lei et al., 2019; Wu et al., 2019, 2020]. Глубокое обучение обычно позволяет проводить более быстрые вычисления, чем моделирование традиционными методами [Guo et al., 2016; Moseley et al., 2020]. Генеративно-сопоставительные сети (generative adversarial networks – GAN) успешно применяются в задаче подавления численной дисперсии [Kaur et al., 2019; Siahkoohi et al., 2019]. В частности, Н. Kaur с соавторами [2019] предлагает использовать GAN для отображения зашумленных данных (моментальных снимков), смоделированных при помощи конечно-разностного метода, в данные, рассчитанные с применением малоранговой экстраполяции.

В данной работе описан оригинальный подход к сейсмическому моделированию, основанный на объединении вычислений конечно-разностным методом с применением искусственной нейронной сети подавления численной дисперсии (Numerical Dispersion Mitigation network – NDM-net). На примере реалистичной 2D модели продемонстрировано, что использование NDM-net сокращает общее время вычислений почти в 10 раз.

ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ NDM-net

Сверточные нейронные сети (Convolutional Neural Network – CNN) обычно применяются в задачах компьютерного зрения. Частным случаем CNN является нейронная сеть U-Net [Ronneberger et al., 2015], разработанная для сегментации биомедицинских изображений. U-net представляет собой глубокую сверточную нейронную сеть, состоящую из кодировщика и декодировщика, соединенных между собой операцией конкатенации. Кодировщик построен из сверточных блоков, которые извлекают высокоуровневые признаки из входных данных и сжимают их в один многомерный тензор меньшей

размерности. Всего в оригинальном U-net используется 23 сверточных слоя, входная размерность изображения составляет 572×572 . В дальнейшем различные модификации этой архитектуры нашли широкое применение не только в задачах сегментации, но также и в задачах регрессии. В настоящее время весь класс таких нейронных сетей (полностью сверточный кодировщик-декодировщик соединенный операцией конкатенации) называют архитектурой типа U-net. В этой работе предлагается использовать NDM-net, являющуюся модификацией сети U-net, с тем чтобы численно построить оператор, переводящий сейсмограммы, рассчитанные на грубой сетке, в сейсмограммы, рассчитанные на мелкой сетке. Другими словами, при помощи глубокого обучения будет проведена постобработка синтетических сейсмических данных для уменьшения ошибки, возникающей из-за численной дисперсии.

Архитектура NDM-net повторяет глубокую нейронную сеть, которая использовалась в работе [Gadylyshin et al., 2020]. Различия заключаются в использовании стандартных сверточных слоев вместо неполных сверточных слоев (partial convolutional layer) и в различающихся размерностях ввода/вывода (рис. 1). Нейронная сеть содержит 16 сверточных слоев, восемь слоев масштабирования и восемь слоев конкатенации. Размерность входного и выходного тензоров: $1280 \times 512 \times 2$. Функция активации для первых восьми сверточных слоев, которые отвечают за кодирование или извлечение признаков, – ReLU (линейная ректификация) [Fukushima, 1969], а для последних восьми, представляющих часть декодировщика, функция активации – LeakyReLU (линейная ректификация с параметром) [Glorot et al., 2011] с отрицательным коэффициентом наклона, равным 0.2. Для программной реализации использовалась библиотека TensorFlow [Abadi et al., 2015].

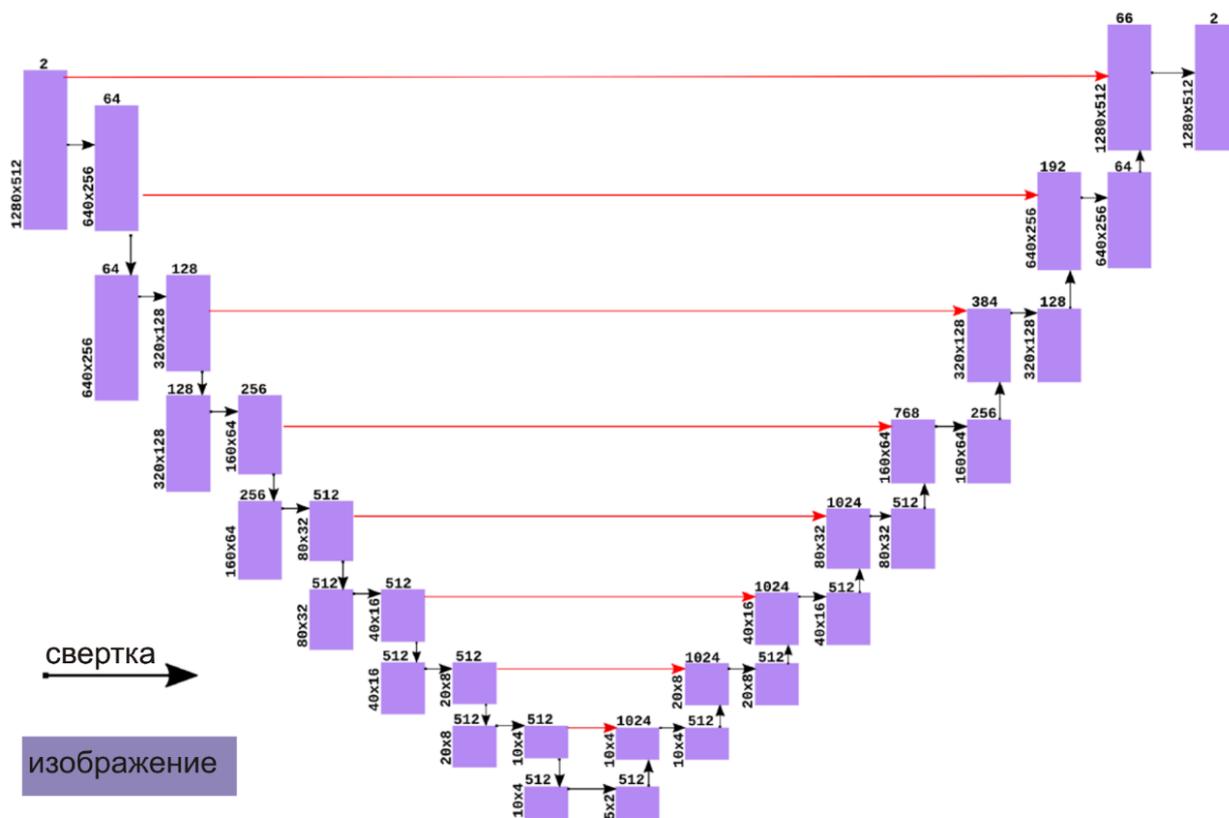


Рис. 1. Архитектура искусственной нейронной сети NDM-net

Вход и выход NDM-net – это сейсмограммы, записанные на свободной поверхности. Для обучения нейронной сети используется каждая 10 сейсмограмма общего пункта возбуждения (ОПВ), предварительно рассчитанная на мелкой сетке, в паре с ее «искаженной» версией, смоделированной на грубой сетке. Для формирования входных данных сейсмограмма преобразуется в тензор размерности $1280 \times 512 \times 2$, где 1280 – количество временных отсчетов в данных (временная дискретизация 4 мс и время записи 5.116 с), 512 – количество приемников 2С, а 2 – количество записанных компонент скорости (вертикальная и горизонтальная). Затем мы разделяем этот набор данных на обучающий набор и валидационный набор. Каждая сейсмограмма перед обработкой NDM-net масштабируется путем приведения к единичной дисперсии и нулевому среднему.

ЧИСЛЕННЫЕ ЭКСПЕРИМЕНТЫ

Рассмотрим упругую модель Marmousi2 [Martin et al., 2006], представленную на рис. 2. Линейные размеры модели составляют 17×3.6 км. Marmousi2 – морская модель и включает слой, моделирующий воду в верхней части. Модель была модифицирована путем замены верхнего слоя воды твердым телом, соответствующим дну океана для этой модели. Чтобы избежать появления поверхностных и кратных волн, вызванных наличием свободной поверхности, модель была расширена для $z < 0$, а для описания границы в полосе $10 < z < 100$ м применен идеально согласованный слой [Collino, Tsogka, 2001]. Поглощающие граничные условия также применялись для всех остальных границ расчетной области. Форма импульса в источнике – вейвлет Рикера с центральной частотой 30 Гц. Распространение сейсмических волн моделировалось с использованием расчетных сеток с шагами 1.25, 2.5 и 5 м, в предположении, что решение, полученное на сетке 1.25 м, является точным. Такой малый шаг сетки был выбран из-за низкоскоростного слоя, введенного вместо слоя воды в верхней части модели. Моделирование проводилось с использованием стандартных сдвинутых сеток четвертого порядка аппроксимации по пространству и второго порядка по времени [Levander, 1988].

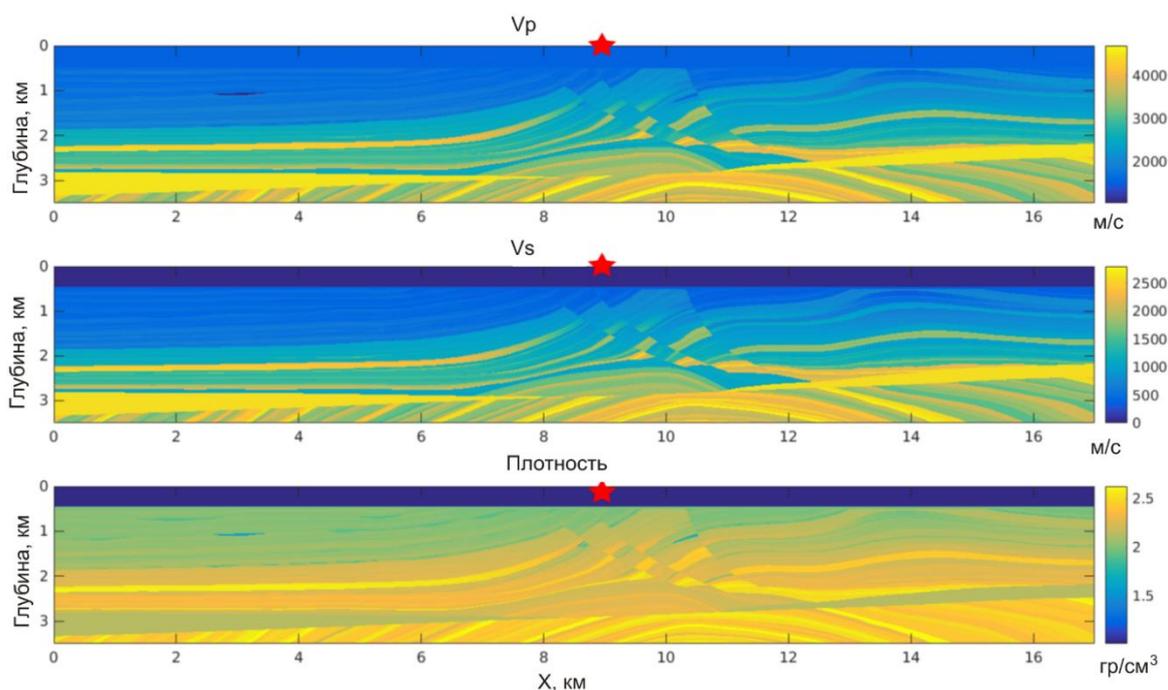


Рис. 2. Модифицированная упругая модель Marmousi2 (скорости и плотность). Красным обозначена позиция источника для $X=9$ км

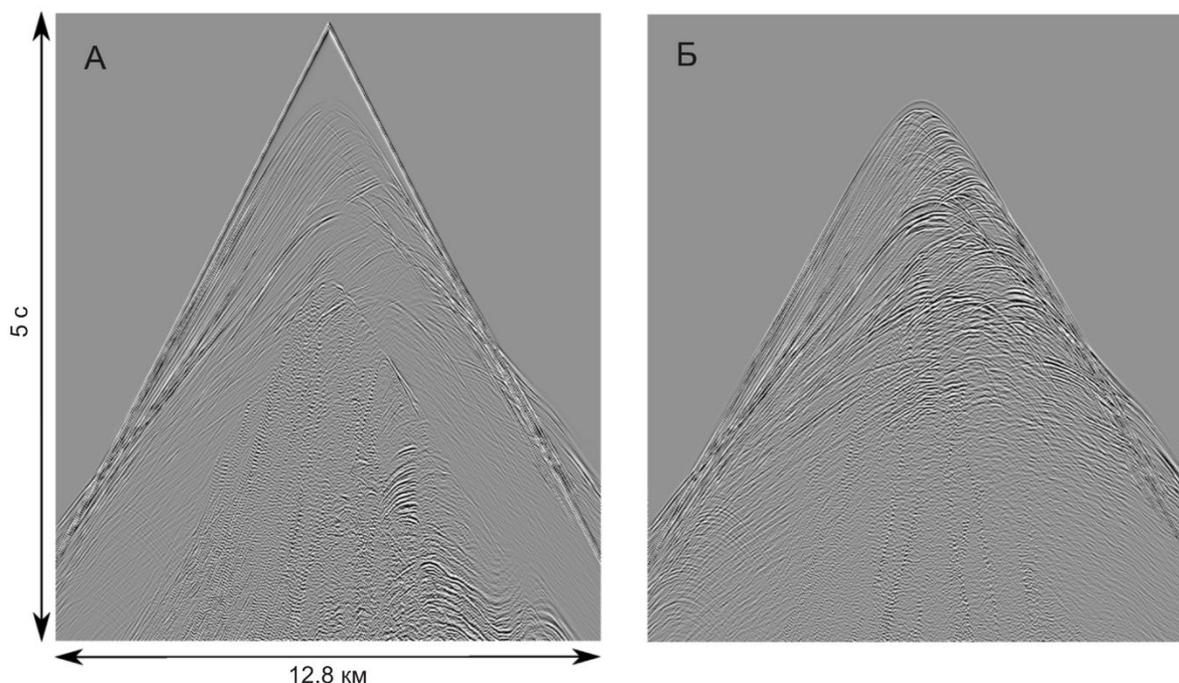


Рис. 3. Сейсмограммы, соответствующие источнику, расположенному в точке $X=9$ км: горизонтальная компонента (А) и вертикальная компонента (Б) скоростей смещений, вычисленные на сетке с шагом 1.25 м

Система наблюдения состоит из 171 источника. Расстояние между соседними источниками составляет 100 м. Двухкомпонентные данные, записанные 512 2С-приемниками, были смоделированы для каждого источника. Максимальное удаление от источника до приемника составило 6.4 км. Расстояние между двумя соседними приемниками составляло 25 м. В среднем время моделирования с использованием графического ускорителя Nvidia V100 для одного источника занимало 5 с при расчете на сетке с шагом 5 м, для сетки с шагом 2.5 м–40 с, и 4 мин для сетки с шагом 1.25 м. Пример смоделированной сейсмограммы на сетке с шагом 1.25 м ($X=9$ км) представлен на рис. 3.

Были рассчитаны три набора данных. Для первого набора данные моделировались на сетке с пространственным шагом 1.25 м. Этот набор данных распределен следующим образом: 10 % данных используется для обучения NDM-net, оставшаяся часть данных используется для верификации алгоритма. Два набора данных, рассчитанных на сетках с шагами по пространству 2.5 и 5 м, содержат видимую численную дисперсию, обусловленную плохой пространственной дискретизацией задачи.

Для того, чтобы ввести количественную меру сходства сейсмограмм, использована нормированная среднеквадратичная ошибка (normalized root mean square – NRMS) [Kragh, Christie, 2002; Kragh, Laws, 2006]. NRMS это строгая поточечная метрика, которая используется для оценки повторяемости сейсмической съемки в процессе сейсмического мониторинга. Как показано на рис. 4, NRMS между данными, полученными с использованием сетки 2.5 м, и точными данными составляет примерно 30%, а для данных, полученных с использованием сетки с шагом 5 м, составляет примерно 60%. В рамках исследования были обучены две NDM-net: первая сопоставляет данные, полученные для расчетной сетки с шагом 2.5 м, с данными для сетки с шагом 1.25 м, а вторая сопоставляет данные для сетки с шагом 5 м с данными для сетки с шагом 1.25 м. В качестве обучающего набора данных использовались всего 17 различных положений источников. Впоследствии нейронная сеть получала на вход весь набор данных, и для всего набора данных вычислялся NRMS между результирующими (обработанными с помощью NDM-net) данными и точным решением.

Сравнение NRMS для одной сейсмограммы (не из обучающей выборки) представлено на рис. 4. В обоих сценариях NDM-net уменьшила среднее значение NRMS примерно вдвое путем подавления численной дисперсии. На графике (рис. 5) показан эффект улучшения данных после применения NDM-net для одной сейсмической трассы, рассчитанной с использованием разных сеток.

В дополнение к графикам NRMS была рассчитана корреляция между волновыми полями, рассчитанными на грубой и на мелкой сетках и предсказанными с помощью NDM-net сейсмограммами. Между двумя сейсмограммами для фиксированного положения источника был рассчитан коэффициент корреляции Пирсона. Затем это значение было рассчитано для всех источников в наборе данных и усреднено. Как можно видеть (табл. 1), корреляция между сейсмограммами существенно улучшилась после применения NDM-net. В итоге корреляция между скорректированными сейсмограммами и данными, насчитанным на сетке с шагом 1.25 м, превысила 90 % для обоих сценариев.

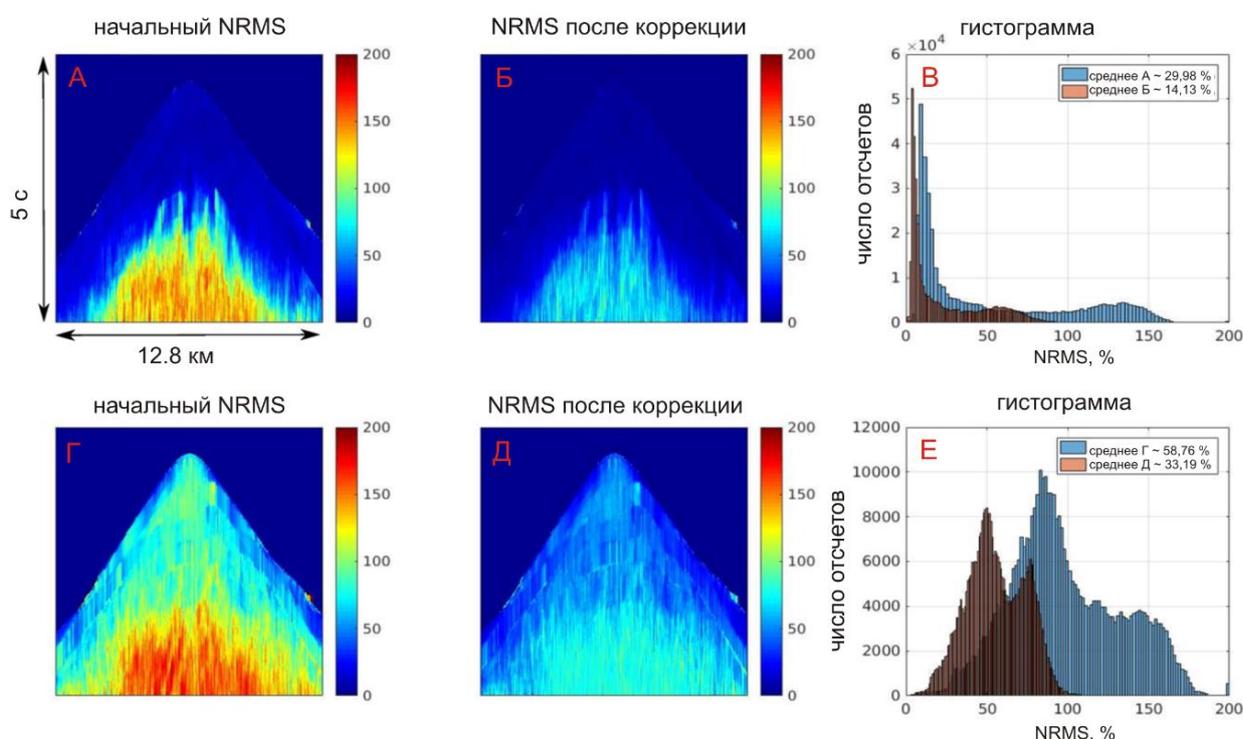


Рис. 4. NRMS, рассчитанный между сейсмограммами на сетке с шагом 1.25 и 2.5 м (А), 1.25 м и скорректированными с помощью NDM-net 2.5 м данными (Б), 1.25 и 5 м (Г), 1.25 м и скорректированными NDM-net 5 м данными (Д), и соответствующие гистограммы (В, Е)

Таблица 1

Корреляция между данными с грубой и мелкой сеткой (первый ряд) и между скорректированными с помощью NDM данными и данными с мелкой сеткой (второй ряд), рассчитанными для модели Marmousi2

Метод расчета	Шаг сетки по пространству	
	2.5 м	5 м
Конечно-разностный	0.9624	0.7634
Конечно-разностный с постобработкой данных NDM-net	0.9925	0.9300

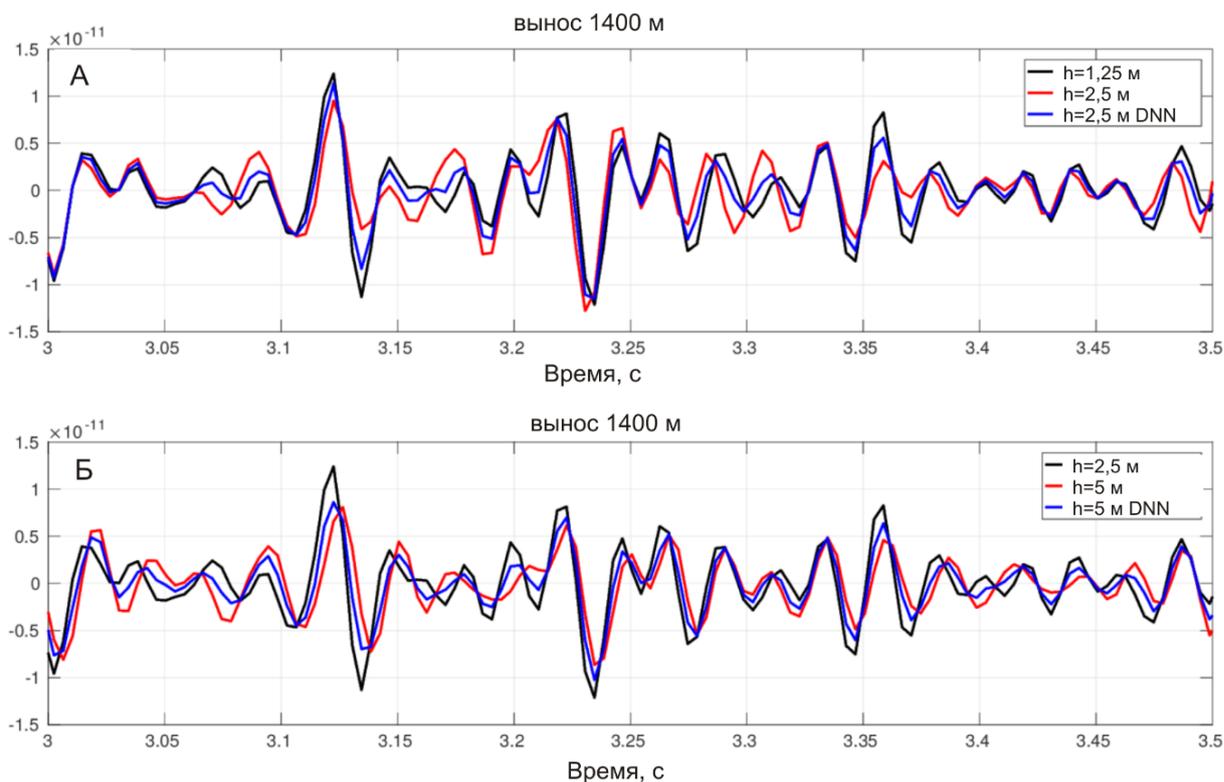


Рис. 5. Сейсмические трассы (вертикальная компонента скорости) для разных положений приемников и предсказанные с помощью NDM-net трассы с подавленной численной дисперсией для случая 2.5 м сетки (А) и 5 м сетки (Б). Черным изображена вертикальная компонента скоростей смещений на мелкой сетке (точное решение), красным – входные данные NDM-net, а синим – скорректированные данные после подавления дисперсии

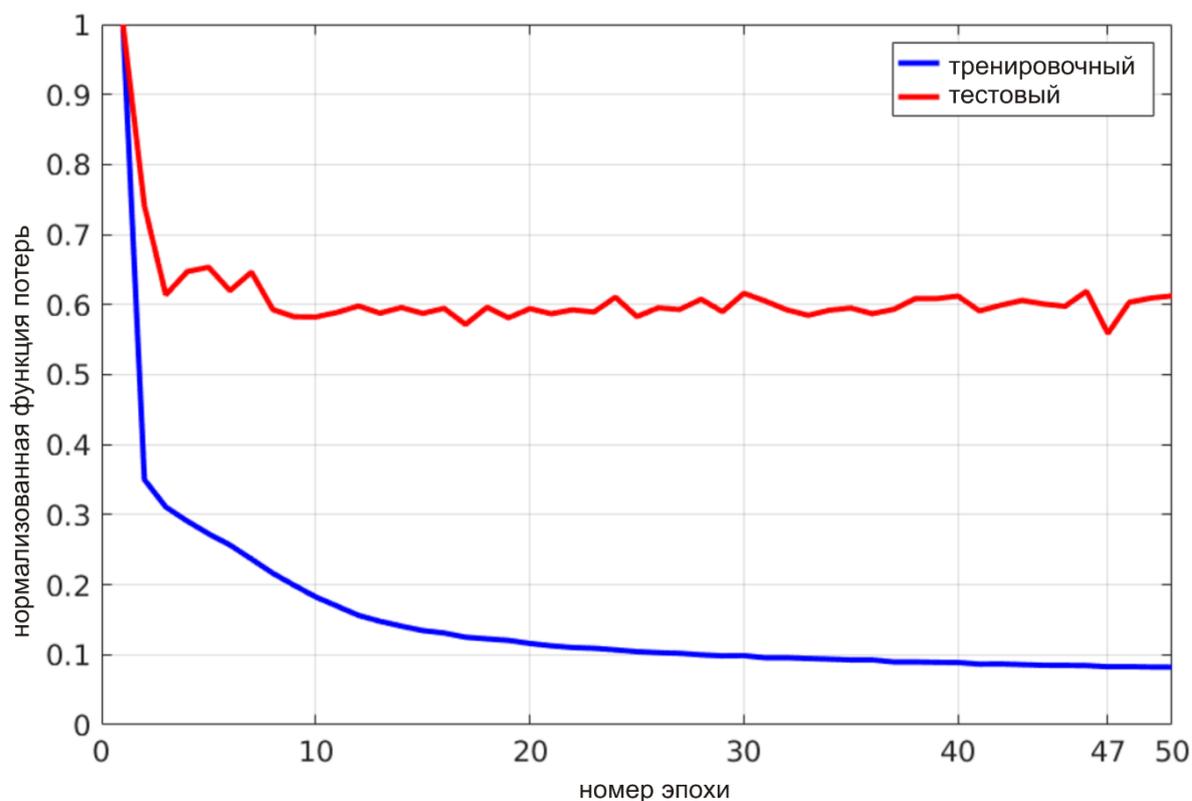


Рис. 6. Поведение нормированного целевого функционала на тренировочном наборе данных (синим) и на валидационном (красным) в процессе обучения NDM-net в зависимости от номера эпохи.

В процессе обучения NDM-net, чтобы избежать переобучения, в качестве регуляризации применялся метод ранней остановки: обучение прерывалось, когда ошибка на проверочном наборе данных (ошибка обобщения) начинала расти (рис. 6). В обоих случаях (2.5 и 5 м) процесс обучения занимал примерно 10 мин. Время предсказания составляло примерно 0.7 с для одного источника. Расчет одной сейсмограммы на графическом ускорителе с использованием конечно-разностной схемы занял примерно 5 с на сетке с шагом 5 м, примерно 40 с на сетке с шагом 2.5 м, а для самой мелкой сетки 1.25 м потребовалось 5 мин машинного времени.

Таким образом, общее время моделирования всего набора данных методом конечных разностей составило 855 с для сетки с шагом 5 м, 6840 с для сетки с шагом 2.5 м и 51300 с (14.25 часа) для сетки с шагом 1.25 м. Обучение и применение NDM-net заняли одинаковое время для обоих случаев, то есть 600 с для обучения и 69 с для применения сети ко всему набору данных. Таким образом, общее время, необходимое для вычисления моделирования сейсмограмм на грубой сетке, вычисления обучающего набора данных, обучения и применения нейронной сети, равно:

$$T = t_f N_f + t_c N + t_{tr} + t_{app} N,$$

где T – общее время, необходимое для расчета полного набора сейсмических данных; t_f и t_c – время расчета одной сейсмограммы на мелкой и грубой сетке соответственно; t_{tr} – время обучения NDM-net; t_{app} – время применения NDM-net для одного источника; N_f – количество сейсмограмм, рассчитанных на мелкой сетке; N – общее количество источников в расстановке. В первом сценарии, когда NDM-net применялась для данных, рассчитанных на сетке 2.5 м, параметры в формуле имели следующие значения: $t_f = 600$ с, $t_c = 40$ с, $N_f = 17$, $N = 171$, $t_{tr} = 600$ с и $t_{app} = 0.7$ с. Таким образом, общее время расчета T составило 17 760 с или 4.9 ч. Для второго сценария, когда NDM-net применялась для подавления численной дисперсии в данных, рассчитанных на сетке с шагом 5 м, t_c составляло 5 с и все остальные параметры остались прежними. Как итог, общее время расчета T составило 11 775 с или 3.2 ч. В результате моделирование на грубой сетке с последующим применением NDM-net (с учетом времени на генерацию обучающей выборки и обучение нейронной сети) в сравнении с расчётом полного набора данных на мелкой сетке происходит в шесть-десять раз быстрее.

ЗАКЛЮЧЕНИЕ

Предложен оригинальный подход к сейсмическому моделированию, сочетающий стандартные конечно-разностные методы с постобработкой полученных сейсмограмм на основе глубокого обучения. Алгоритм состоит из трех основных шагов. На первом шаге генерируется обучающий набор данных, который состоит из обычных сейсмограмм, рассчитанных для небольшого числа источников из всего набора данных. Обучающая выборка рассчитывается с использованием мелкой сетки, обеспечивающей достаточное количество точек на минимальную длину волны (порядка 10), и с использованием грубой сетки, учитывающей порядка 5 точек на минимальную длину волны. Второй шаг — это обучение NDM-net для подавления численной дисперсии в решении, рассчитанном на грубой сетке, то есть построение отображения данных с грубой сетки в данные, рассчитанные на мелкой сетке. На третьем заключительном шаге NDM-net применяется ко всему набору данных, смоделированному с использованием грубой сетки.

Описанный метод был апробирован на сложной синтетической реалистичной модели Magmou2. Расчет всего набора данных конечно-разностным методом с использованием мелкой расчетной сетки

занял примерно 28 часов машинного времени. Решение той же задачи с использованием NDM-net занимало от трех до пяти часов, в зависимости от дискретизации грубой сетки. Было показано, что представленный подход позволяет ускорить на порядок общее время проведения сейсмического моделирования для всей геометрии системы наблюдения.

Вадим Лисица, Ксения Гадильшина разработали алгоритм построения оптимальной обучающей выборки и выполнили численные эксперименты по обучению NDM-net сети для различных сценариев при поддержке Российского научного фонда грант № 22-11-00004. Кирилл Гадильшин оптимизировал гиперпараметры нейронной сети NDM-net при поддержке Российского научного фонда грант № 22-21-00738. Дмитрий Вишневецкий провел моделирование сейсмических данных при поддержке проекта ФНИ 0266-2022-0022

ЛИТЕРАТУРА

REFERENCES

Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Mané D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner B., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Viégas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X. TensorFlow: large-scale machine learning on heterogeneous distributed systems. – 2015, <http://download.tensorflow.org/paper/whitepaper2015.pdf>.

Chen J.-B. A 27-point scheme for a 3D frequency-domain scalar wave equation based on an average-derivative method // *Geophysical Prospecting*. – 2014. – Vol. 62 (2). – P. 258–277, doi: 10.1111/1365-2478.12090.

Collino F., Tsogka C. Application of the perfectly matched layer absorbing layer model to the linear elastodynamic problem in anisotropic heterogeneous media // *Geophysics*. – 2001. – Vol. 66. – P. 294–307, doi: 10.1190/1.1444908.

Fukushima K. Visual feature extraction by a multilayered network of analog threshold elements // *IEEE Transactions on Systems Science and Cybernetics*. – 1969. – Vol. 5 (4). – P. 322–333, doi: 10.1109/TSSC.1969.300225.

Gadylyshin K., Silvestrov I., Bakulin A. Inpainting of local wavefront attributes using artificial intelligence for enhancement of massive 3-D pre-stack seismic data // *Geophysical Journal International*. – 2020. – Vol. 223 (3). – P. 1888–1898, doi: 10.1093/gji/ggaa422.

Glorot X., Bordes A., Bengio Y. Deep sparse rectifier neural networks // *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, PMLR. – 2011. – Vol. 15. – P. 315–323, <https://proceedings.mlr.press/v15/glorot11a.html>.

Guo X., Li W., Iorio F. Convolutional neural networks for steady flow approximation // *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. – San Francisco, CA, USA, 2016. – P. 481–490, doi: 10.1145/2939672.2939738.

Kaur H., Fomel S., Pham N. Overcoming numerical dispersion of finite-difference wave extrapolation using deep learning / *SEG Technical Program Expanded Abstracts*. – 2019. – P. 2318–2322, doi: 10.1190/segam2019-3207486.1.

Kragh E., Christie P. Seismic repeatability, normalized RMS, and predictability // *The Leading Edge*. – 2002. – Vol. 21 (7). – P. 640–647, doi: 10.1190/1.1497316.

- Kragh E., Laws R.** Rough seas and statistical deconvolution // *Geophysical Prospecting*. – 2006. – Vol. 54 (4). – P. 475–485, doi: 10.1111/j.1365-2478.2006.00549.x.
- Lei L., Yu L., Xiong Z., Han L., Wei X., Shifan Z.** Convolutional recurrent neural networks based waveform classification in seismic facies analysis // *SEG Technical Program Expanded Abstracts*. – 2019. – P. 2599–2603, doi: 10.1190/segam2019-3215237.1.
- Levander A.R.** Fourth-order finite-difference P-SV seismograms // *Geophysics*. – 1988. – Vol. 53 (11). – P. 1425–1436, doi: 10.1190/1.1442422.
- Liu Y.** Optimal staggered-grid finite-difference schemes based on least-squares for wave equation modelling // *Geophysical Journal International*. – 2014. – Vol. 197 (2). – P. 1033–1047, doi: 10.1093/gji/ggu032.
- Liu Y., Sen M.K.** A new time–space domain high-order finite-difference method for the acoustic wave equation // *Journal of Computational Physics*. – 2009. – Vol. 228 (23). – P. 8779–8806, doi: 10.1016/j.jcp.2009.08.027.
- Martin G.S., Wiley R., Marfurt K.J.** Marmousi2: An elastic upgrade for Marmousi // *The Leading Edge*. – 2006. – Vol. 25 (2). – P. 156–166, doi: 10.1190/1.2172306.
- Moseley B., Nissen-Meyer T., Markham A.** Deep learning for fast simulation of seismic waves in complex media // *Solid Earth*. – 2020. – Vol. 11. – P. 1527–1549, doi: 10.5194/se-11-1527-2020.
- Ronneberger O., Fischer P., Brox T.** U-Net: convolutional networks for biomedical image segmentation // *Medical Image Computing and Computer-Assisted Intervention. MICCAI 2015. Lecture Notes in Computer Science*. – 2015. – Vol. 9351. – P. 234–241, doi: 10.1007/978-3-319-24574-4_28.
- Siahkoobi A., Louboutin M., Herrmann F.J.** The importance of transfer learning in seismic modeling and imaging // *Geophysics*. – 2019. – Vol. 84 (6). – P. A47–A52, doi: 10.1190/geo2019-0056.1.
- Tan S., Huang L.** A staggered-grid finite-difference scheme optimized in the time–space domain for modeling scalar-wave propagation in geophysical problems // *Journal of Computational Physics*. – 2014. – Vol. 276. – P. 613–634, doi: 10.1016/j.jcp.2014.07.044.
- Virieux J.** P-SV wave propagation in heterogeneous media: Velocity-stress finite-difference method // *Geophysics*. – 1986. – Vol. 51 (4). – P. 889–901, doi: 10.1190/1.1442147.
- Virieux J., Operto S., Ben-Hadj-Ali H., Brossier R., Etienne V., Sourbier F., Giraud L., Haidar A.** Seismic wave modeling for seismic imaging // *The Leading Edge*. – 2009. – Vol. 28 (5). – P. 538–544, doi: 10.1190/1.3124928.
- Virieux J., Calandra H., Plessix R.-E.** A review of the spectral, pseudo-spectral, finite-difference and finite-element modelling techniques for geophysical imaging // *Geophysical Prospecting*. – 2011. – Vol. 59 (5). – P. 794–813, doi: 10.1111/j.1365-2478.2011.00967.x.
- Wu H., Zhang B., Lin T., Cao D., Lou Y.** Semiautomated seismic horizon interpretation using the encoder-decoder convolutional neural network // *Geophysics*. – 2019. – Vol. 84 (6). – P. B403–B417, doi: 10.1190/geo2018-0672.1.
- Wu X., Geng Z., Shi Y., Pham N., Fomel S., Caumon G.** Building realistic structure models to train convolutional neural networks for seismic structural interpretation // *Geophysics*. – 2020. – Vol. 85. – P. WA27–WA39, doi: 10.1190/geo2019-0375.1.
- Yu S., Ma J.** Deep Learning for Geophysics: Current and Future Trends // *Reviews of Geophysics*. – 2021. – Vol. 59 (3). – e2021RG000742, doi: 10.1029/2021RG000742.

Yu S., Ma J.van, Wang W. Deep learning for denoising // *Geophysics*. – 2019. – Vol. 84. – P. V333–V350, doi: 10.1190/geo2018-0668.1.

Zhu W., Mousavi S.M., Beroza G.C. Seismic signal denoising and decomposition using deep neural networks // *IEEE Transactions on Geoscience and Remote Sensing*. – 2019. – Vol. 57 (11). – P. 9476–9488, doi: 10.1109/TGRS.2019.2926772.

КОРОТКО ОБ АВТОРАХ

ГАДЫЛЬШИНА Ксения Александровна – младший научный сотрудник лаборатории вычислительной физики горных пород Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: методы машинного обучения в приложении к решению задач геофизики.

ЛИСИЦА Вадим Викторович – кандидат физико-математических наук, заведующий лабораторией вычислительной физики горных пород Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: численные методы для моделирования физических процессов в пористых средах.

ВИШНЕВСКИЙ Дмитрий Михайлович – младший научный сотрудник лаборатории вычислительной физики горных пород Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: численное моделирование сейсмических волновых полей, высокопроизводительные вычисления.

ГАДЫЛЬШИН Кирилл Геннадьевич – кандидат физико-математических наук, старший научный сотрудник лаборатории вычислительной физики горных пород Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: прямые и обратные задачи сейсмологии, применение методов машинного обучения для повышения качества сейсмических данных.

*Статья поступила в редакцию 9 августа 2022 г.,
принята к публикации 25 октября 2022 г.*