

Е. А. Гондюл^{1}, В. В. Лисица¹, Д. М. Вишневецкий¹*

Использование акустических данных для обучения NDM-net при сейсмическом моделировании

¹ Институт нефтегазовой геологии и геофизики им. А.А. Трофимука Сибирского отделения Российской академии наук (ИНГГ СО РАН), г.Новосибирск, Российская Федерация
* e-mail: gondyulea@ipgg.sbras.ru

Аннотация. Данная работа посвящена обобщению применения нейронной сети NDM-net (Numerical Dispersion Mitigation neural network) на случай, когда обучение производится на данных акустического моделирования с последующим применением к решению системы уравнений динамической теории упругости. Рассчитываются акустические данные для каждого источника с использованием грубой сетки, далее для 10-20% источников решается уравнение акустики на мелкой сетке для формирования обучающей выборки. Нейронная сеть обучается на такой репрезентативной выборке с последующим применением ко всем данным сейсмического моделирования с использованием грубой сетки. Показано, что нейронная сеть подавляет численную дисперсию в акустических данных в 3 раза, однако в данных упругости лишь на 10%.

Ключевые слова: сейсмическое моделирование, акустические данные, нейронные сети

E. A. Gondyul^{1}, V. V. Lisitsa¹, D. M. Vishnescky¹*

Using acoustic data for NDM-net training in seismic modeling

¹ Trofimuk Institute of Petroleum Geology and Geophysics of Siberian Branch Russian Academy of Sciences (IPGG SB RAS), Novosibirsk, Russian Federation
* e-mail: gondyulea@ipgg.sbras.ru

Abstract. This paper presents a study on the generalizability of the NDM-net (Numerical Dispersion Mitigation Neural Network) when applied to acoustic modeling data for use in solving a system of dynamic elasticity equations. Acoustic data are calculated for each source using a coarse grid and, for 10-20% of sources, an acoustic equation is solved on a fine grid to create a training sample. The neural network is then trained on this representative sample and applied to all seismic modeling data using a coarse grid. Results show that the neural network reduces the numerical dispersion of acoustic data by a factor of 3, but only reduces it by 10% for elasticity data.

Keywords: seismic modelling, acoustic data, neural network

Введение

Одним из важных этапов обработки сейсмических данных является сейсмическое моделирование. Существуют множество методов численного решения системы уравнений динамической теории упругости такие, как конечные разности [1], разрывного Галёркина [2], метод спектральных элементов [3] и другие. Однако все существующие методы зачастую требуют высокопроизводительных вычислений, при этом уменьшение шага сетки или порядка аппроксимации для

ускорения моделирования приводит к численным ошибкам. В частности, появляется численная дисперсия, связанная с аппроксимацией пространственных производных в дифференциальном операторе. Ранее было предложено использовать нейронную сеть для подавления такого вида погрешности [4,5]. Нейронная сеть NDM-net (Numerical Dispersion Mitigation network), используя архитектуру U-net, переводит сейсмограммы, рассчитанные на грубой сетке, в сейсмограммы, рассчитанные на мелкой. Так, аппроксимируется оператор перехода с помощью нейронной сети в результате обучения.

В настоящей работе предлагается исследовать вопрос о подавлении численной дисперсии с использованием акустических данных для ускорения сейсмического моделирования. Такое исследование поможет расширить функционал NDM-net.

Предварительные замечания

Рассмотрим уравнение акустики в терминах давления и скорости в двумерной постановке:

$$\begin{aligned} \rho \frac{\partial u}{\partial t} &= \frac{\partial p}{\partial z}, \\ \frac{\partial p}{\partial t} &= \lambda \nabla \cdot u + \hat{f}, \end{aligned} \quad (1)$$

где p – давление, $u = (u_1, u_3)^T$ – вектор скоростей смещений; $\rho = \rho(x, z)$ – плотность; $\lambda = \lambda(x, z)$ – параметр Ламе; $\hat{f} = (\hat{f}_1, \hat{f}_3) = (f_1(t)\delta(x - x_s)\delta(z - z_s), f_3(t)\delta(x - x_s)\delta(z - z_s))$ – вектор сейсмических моментов.

Также, рассмотрим двумерную систему уравнений динамической теории упругости для получения волновых полей в упругой среде:

$$\begin{aligned} \rho(\vec{x}) \frac{\partial u_1}{\partial t} &= \frac{\partial \sigma_{11}}{\partial x_1} + \frac{\partial \sigma_{13}}{\partial x_3} + f_1(t)\delta(\vec{x} - \vec{x}_j^s), \\ \rho(\vec{x}) \frac{\partial u_3}{\partial t} &= \frac{\partial \sigma_{13}}{\partial x_1} + \frac{\partial \sigma_{33}}{\partial x_3} + f_3(t)\delta(\vec{x} - \vec{x}_j^s), \\ \frac{\partial \sigma_{11}}{\partial t} &= (\lambda(\vec{x}) + 2\mu(\vec{x})) \frac{\partial u_1}{\partial x_1} + \lambda(\vec{x}) \frac{\partial u_3}{\partial x_3} + g_{11}(t)\delta(\vec{x} - \vec{x}_j^s), \\ \frac{\partial \sigma_{33}}{\partial t} &= \lambda(\vec{x}) \frac{\partial u_1}{\partial x_1} + (\lambda(\vec{x}) + 2\mu(\vec{x})) \frac{\partial u_3}{\partial x_3} + g_{33}(t)\delta(\vec{x} - \vec{x}_j^s), \\ \frac{\partial \sigma_{13}}{\partial t} &= \mu(\vec{x}) \frac{\partial u_1}{\partial x_3} + \mu(\vec{x}) \frac{\partial u_3}{\partial x_1} + g_{13}(t)\delta(\vec{x} - \vec{x}_j^s) \end{aligned} \quad (2)$$

где $\vec{u} = (u_1, u_3)^T$ – вектор скорости смещений; $\sigma_{11}, \sigma_{33}, \sigma_{13}$ – компоненты тензора напряжений; $\rho(\vec{x})$ – плотность; $\lambda(\vec{x}), \mu(\vec{x})$ – параметры Ламэ; $\vec{f} = (f_1, f_3)^T$ – вектор внешних сил; g_{11}, g_{33}, g_{13} – компоненты тензора сейсмиче-

ских моментов; $\vec{x} = (x_1, x_3)^T$ – вектор координат; δ – дельта-функция Дирака; \vec{x}_j^s – координата j -ого источника.

Система (1) и (2) решаются также конечно-разностным методом на сдвинутых сетках. Система (1) решается с использованием грубой сетки для каждого источника и мелкой сетке для 10% источников для формирования обучающей выборки, в то время как система (2) решается только на грубой сетке для каждого источника.

Нейронная сеть

В данной работе используется нейронная сеть, основанная на архитектуре U-net. Такая модель хорошо обобщается и показывает качественные результаты в задаче преобразования изображений в другие изображения из-за своих пропускных соединений. Используется ранее разработанная NDM-net для двумерного случая, которая предназначена была подавлять численную дисперсию [4,5]. Модель содержит кодёр, который имеет 8 слоёв операции двумерной свёртки, функцию активации $ReLU(\cdot) = \max(0, \cdot)$ и декодер, имеющего 8 слоёв обратной операции свёртки и функцию активации $LeakyReLU(\cdot) = \max(0, \cdot) + \min(0, \cdot)$ с отрицательным коэффициентом $c = -0.2$. Для оценки количества эпох обучения, используется метод ранней остановки.

Для сжатия данных используется быстрое преобразование Фурье за счет взятия только положительной части спектра. Размер входных данных составляет $1024 \times 1024 \times 2 \times B_n$, где 1024 – количество частот, 1024 – количество отсчётов в трассе, 2 – вещественная и мнимая компонента, B_n – размер пакета.

Входные данные

В качестве входных данных используется данные моделирования на ВР скоростной модели, которая имеет контрастное соляное тело в центре и плавное изменение скоростей справа (рис. 1). Система наблюдения состоит из 2696 источников с расстоянием 25 м друг от друга. Отклики от каждого источника регистрируются 1024 приёмниками, расположенных на расстоянии 12.5 м, так максимальный выброс составляет 6.4 км.

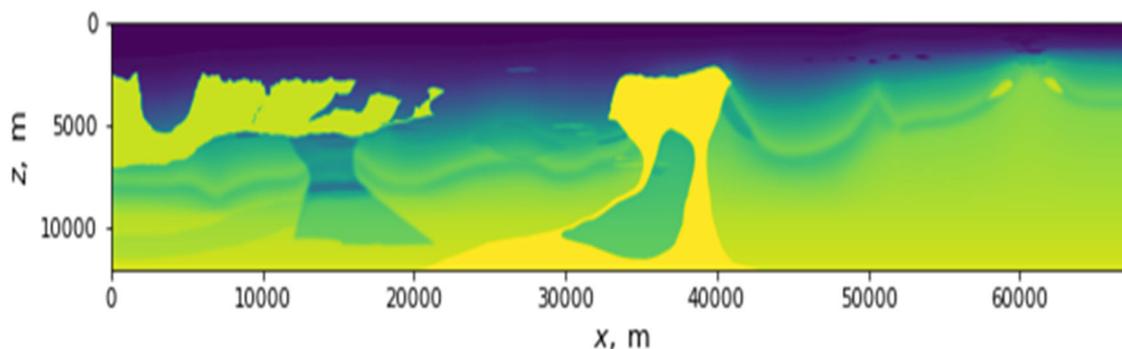


Рис. 1. Скоростная модель ВР

Для решения акустической и упругой задачи использовалась одна и та же скоростная модель и одна и та же расчётная сетка с шагом 6.125 м. Шаг временной дискретизации составляет 3 мс с конечным временем – 6 с.

Результаты

В данном разделе приведены численные эксперименты, а также сравнение времён расчёта акустических данных и данных упругой среды. Приведено время обучения в зависимости от размера обучающей выборки.

Используется следующая относительная ошибка для верификации результатов:

$$L_2^{rel}(d, d_{gen}) = \frac{\|d - d_{gen}\|_2}{\|d\|_2} \times 100\%, \quad (3)$$

где d – данные, рассчитанные на мелкой сетке; d_{gen} – предсказанные данные нейронной сетью.

Первый эксперимент посвящён подавлению численной дисперсии в акустических данных с использованием NDM-net. Для этого рассчитывались акустические данные для всех источников с использованием грубой сетки и для 10% равноудалённых источников с использованием мелкой сетки для формирования обучающей выборки. Для этого случая, относительная ошибка для каждого положения источника приведена на рис.2. Так, численная дисперсия в акустических данных подавляется примерно в 3 раза.

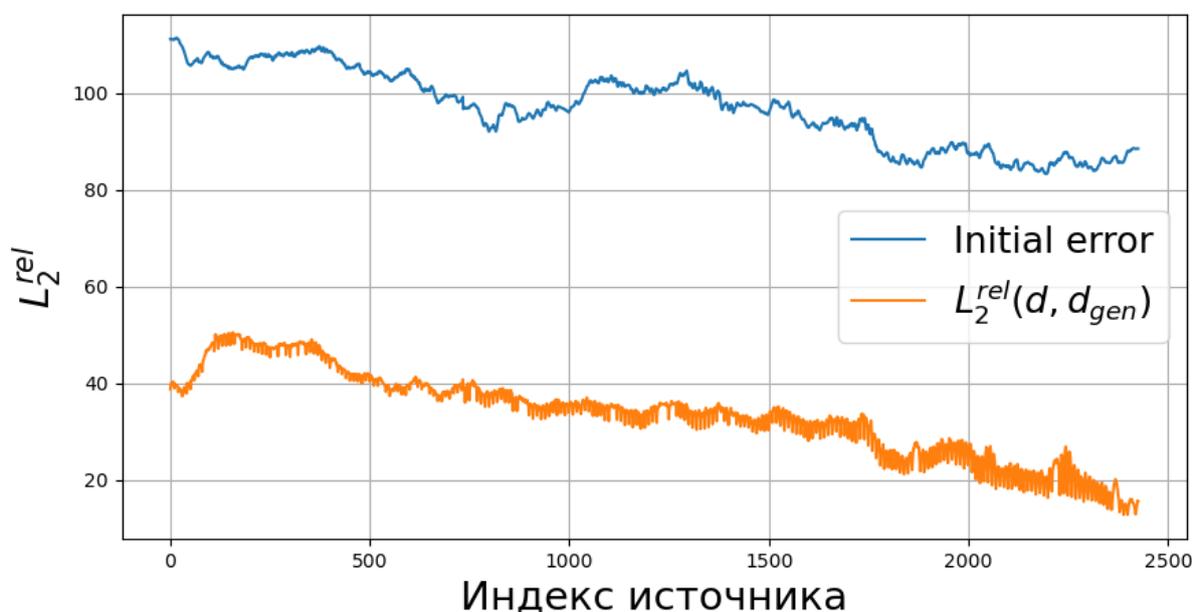


Рис. 2. Изначальная и результирующая относительная ошибка для каждого положения источника в случае подавления численной дисперсии в акустических данных

После того, как аппроксимирован оператор перехода данных, рассчитанных на грубой сетке, в данные, рассчитанные на мелкой, с помощью нейронной сети, можно применить обученную нейронную сеть на данные упругости, рассчитанные на грубой сетке. На рис. 3 приведены результаты такого эксперимента. Так, можно заметить, что численная дисперсия в данных упругости подавляется лишь на 10% с использованием обученной нейронной сети на акустических данных.

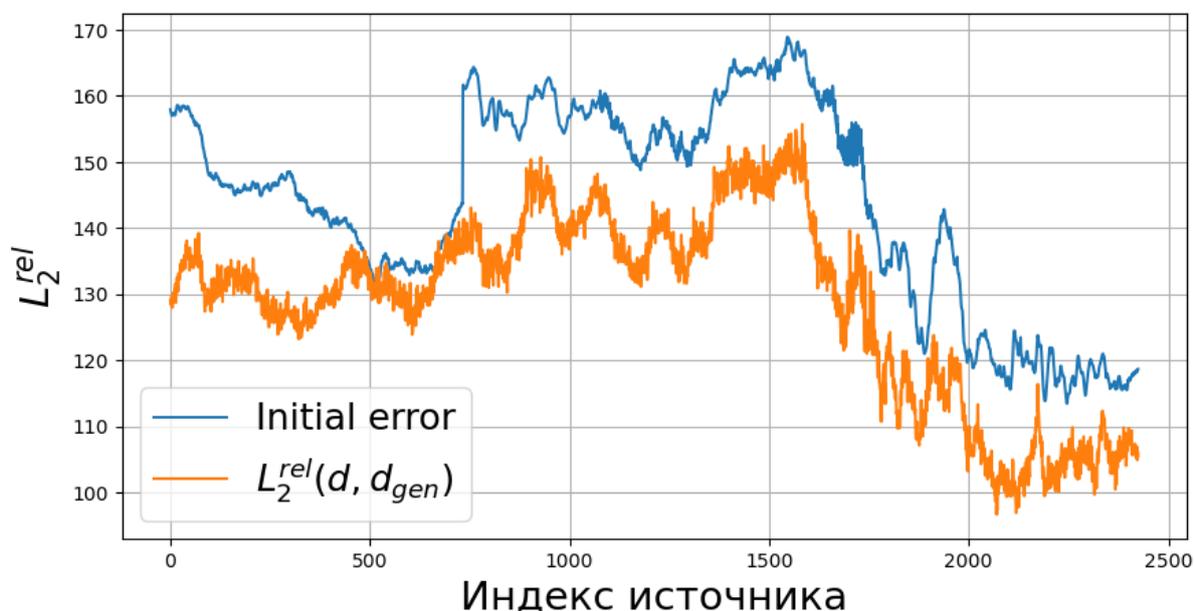


Рис. 3. Изначальная и результирующая относительная ошибка для каждого положения источника в случае подавления численной дисперсии в данных упругости

Время расчёта акустических данных для одного источника на грубой сетке с шагом $h = 6.25$ м составляет 1,938 мин, на мелкой сетке с шагом $h = 3.125$ м составляет 12,3951 мин. Так, расчёт общего набора акустических данных на грубой сетке совместно с 10% акустических данных на мелкой сетке составляет примерно 143 часа. В то время как расчёт одной сейсмограммы на грубой сетке с шагом $h = 6.25$ м для упругой задачи занимает 5,124 мин, на мелкой сетке с шагом $h = 3.125$ м занимает 33.737 мин. На рис. 4 приведена линейная зависимость времени обучения от размера обучающей выборки. Таким образом, подавление численной дисперсии в акустических данных с помощью нейронной сети ускоряет моделирование примерно в 3.8 раз по сравнению с моделированием на мелкой сетке, если брать обучающую выборку размером 10%. Для случая же применения уже обученной NDM-net на решение системы уравнений (2) с использованием грубой сетки, сейсмического моделирование ускоряется в 10-11 раз. Однако, численная дисперсия в этом случае подавляется мало.

Следует отметить, что считались сейсмические данные и обучалась нейронная сеть на графической карте NVIDIA GeForce RTX 3090 с 8 GB памяти.

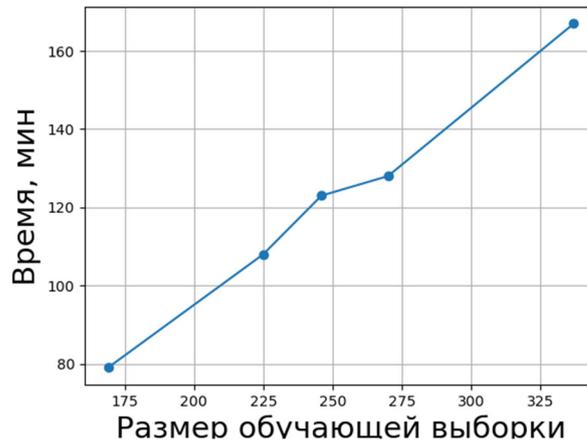


Рис. 4. Время обучения NDM-net в зависимости от размера обучающей выборки

Обсуждение

В работе показано, что нейронная сеть NDM-net, обученная на акустических данных, подавляет численную дисперсию в акустических данных на несколько порядков больше, чем если бы применялась к той же обученной нейронной сети данные упругости. Это означает, что нейронная сеть может применяться лишь к одному типу данных, на которых обучалась.

Заключение

Данная статья посвящена исследованию расширения функционала нейронной сети NDM-net, которая изначально была предназначена для подавления численной дисперсии в сейсмических данных. Предлагается использовать нейронную сеть для аппроксимации оператора перехода из акустических данных, рассчитанных на грубой сетке, в акустические данные, рассчитанные на мелкой. Далее, обученную нейронную сеть предлагается применить к численному решению системы уравнений динамической теории упругости на грубой сетке. Результаты обучения показали, что в то время как численная дисперсия в акустических данных подавляется в 3 раза, при применении обученной нейронной сети на данные упругости численная дисперсия подавляется лишь на 10%.

Благодарности

Авторы выражают благодарность за финансовую поддержку РФФ № 22-11-00004.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Virieux J. P-SV wave propagation in heterogeneous media: Velocity-stress finite-difference method // *Geophysics*. – 1986. – Vol. 51. – № 4. – P. 889-901.
2. Dumbser M., Kaser M. An arbitrary high-order discontinuous Galerkin method for elastic waves on unstructured meshes – II. The three-dimensional isotropic case // *Geophysical Journal International*. – 2006. – Vol. 167. – № 1. – P.319-336.
3. Tromp J., Komatitsch D., Liu Q. Spectral-element and adjoint methods in seismology // *Communications in Computational Physics*. – 2008. – Vol. 3. – № 1. – P. 1-32.

4. Gadylshin K., Vishnevsky D., Gadylshina K., Lisitsa V. Numerical dispersion mitigation neural network for seismic modeling // *Geophysics*. – 2022. – Vol. 87. – № 3. – P. T237-T249.

5. Гадьльшина К. А., Лисица В. В., Вишневский Д. М., Гадьльшин К. Г. Искусственная нейронная сеть, уменьшающая численную дисперсию, для постобработки результатов сейсмического моделирования // *Геофизические технологии*. – 2022. – № 1. – С.99-109.

© *Е. А. Гондюл, В. В. Лисица, Д. М. Вишневский, 2024*