Геофизические технологии, № 1, 2023, с. 54–65 **www.rjgt.ru**
doi: 10.18303/2619-1563-2023-1-54 УДК 550.34.012

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АДАПТИВНОГО ВЫЧИТАНИЯ КРАТНЫХ ОТРАЖЕННЫХ ВОЛН

А.М. Камашев[1,2], А.А. Дучков[1,2]

[1]*Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН, 630090, Новосибирск, просп. Акад. Коптюга, 3, Россия,*
[2]*Новосибирский государственный университет, 630090, Новосибирск, ул. Пирогова, 1, Россия,*
e-mail: a.kamashev@g.nsu.ru

Данная работа посвящена разработке и тестированию алгоритма адаптивного вычитания кратных отраженных волн с помощью сверточной нейронной сети. Алгоритм является одним из основных этапов в методе подавления кратных отраженных волн, основанном на разделении волновых форм в области Радона. В работе рассматривается постановка задачи для нейронной сети, подготовка обучающего и тестового наборов данных и тестирование алгоритма. Использование сверточной нейронной сети позволяет автоматизировать и ускорить процедуру адаптивного вычитания. Тестирование алгоритма проводилось на синтетических данных и показало эффективную адаптацию кратных волн, а также важность корректного построения модели кратных отраженных волн.

Сверточная нейронная сеть, высокоразрешающее преобразование Радона, кратные волны

APPLICATION OF MACHINE LEARNING FOR ADAPTIVE SUBTRACTION OF MULTIPLE REFLECTED WAVES

A.M. Kamashev[1,2], A.A. Duchkov[1,2]

[1]*Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, Koptyug Ave., 3, Novosibirsk, 630090, Russia*
[2]*Novosibirsk State University, Pirogova Str., 1, Novosibirsk, 630090, Russia,*
e-mail: a.kamashev@g.nsu.ru

This work is devoted to the development and testing of an algorithm for adaptive subtraction of multiple reflected waves using a convolutional neural network. The algorithm is one of the main steps in the method of suppression of multiple reflected waves based on the separation of wave forms in the Radon region. The paper considers the formulation of a problem for a neural network, the preparation of training and test data sets and the testing of the algorithm. Using a convolutional neural network allows to automate and speed up the adaptive subtraction procedure. The algorithm was tested on synthetic data. Testing shows the effective adaptation of multiple waves, as well as the importance of correctly constructing a model of multiples.

Convolution neural network, high-resolution Radon transform, multiple waves

ВВЕДЕНИЕ

Сейсморазведка методом отраженных волн (МОВ) является ключевым методом изучения структуры осадочных бассейнов. В МОВ полезными волнами являются однократно отраженные волны. Помимо полезных волн в сейсмической записи присутствуют также волны-помехи. К интенсивным

© А.М. Камашев, А.А. Дучков, 2023

помехам относятся кратные волны – волны, совершившие два или более отражений от границ раздела геологических сред, включая поверхность Земли [Боганик, Гурвич, 2006]. Наличие кратных волн приводит к появлению ложных границ на сейсмическом разрезе. Поэтому подавление подобных помех является важной процедурой в обработке сейсморазведочных данных.

Техники подавления кратных отраженных волн могут быть разделены на две категории [Verschuur, 2013]:

- методы, основанные на различии кратных и однократных по кинематическим характеристикам (например, разделение волн в области Радона);
- методы, основанные на предсказании кратных волн (например, SRME).

Данная работа посвящена методу подавления кратных отраженных волн, основанному на разделении волновых форм в области Радона – область (t, p), где t – время прихода волны, p – кривизна [Hampson, 1986]. Использование преобразования Радона позволяет разделить интерферирующие волны по кривизне. Зачастую для упрощения задачи разделения волновых форм предварительно спрямляют волновые формы путем введения кинематической поправки. Таким образом, все целевые отражения (спрямленные волновые формы) должны быть сконцентрированы в области с низким значением кривизны, а кратные отражения (недо- или переспрямленные) должны быть в области с большими значениями кривизны. В итоге мы можем выделить основные этапы процедуры подавления кратных:

1) введение кинематической поправки по известному скоростному закону;
2) переход в область Радона;
3) подавление целевых отражений;
4) сопряженное преобразование Радона – получение модели кратных;
5) адаптивное вычитание модели кратных из исходной сейсмической записи.

Существует несколько типов преобразования Радона, в зависимости от типа траектории, по которой происходит суммирование: 1) линейный; 2) параболический; 3) гиперболический. Однако отраженные волны имеют гиперболическую форму, поэтому для повышения точности целесообразнее использовать именно гиперболическое преобразование Радона. Также для повышения точности используется высокоразрешающее преобразование Радона, суть которого заключается в минимизации разницы между исходными данными и данными после сопряженного преобразования Радона [Chen et al., 2021]. И тем не менее модель кратных отраженных волн является всего лишь приближением к истинным кратным отражениям. На практике высокоразрешающее преобразование Радона позволяет достаточно точно восстановить кинематику волн, но при этом динамические показатели получаются неточными. Из-за невозможности прямого вычитания модели кратных из сейсмической записи, необходимо использовать адаптивное вычитание.

Существует несколько подходов адаптивного вычитания и большое количество их вариаций. Выделим две основные группы: 1) адаптация сигнала в окне на основе фильтра Винера и [Yilmaz, 2001]; 2) разложение сейсмических данных по базисным функциям, например, разложение по кёрвлетам [Neelamani et al., 2010].

Наиболее распространенный метод адаптивного вычитания основан на использовании двумерных фильтров. Параметры фильтра подбираются таким образом, чтобы при применении к модели кратных он наилучшим образом совпадал с исходной сейсмической записью с точки зрения наименьших квадратов. Однако если внутри окна фильтра на исходной сейсмограмме будут присутствовать не только кратные отражения, но и однократные, то скорее всего они будут вычтены. Поэтому размер фильтра по временной

компоненте должен быть меньше интервала между двумя событиями. На практике же используют комбинацию фильтров больших и маленьких размеров. Глобальные фильтры используются для получения грубой оценки, а фильтры маленьких размеров для локальных уточнений [Verschuur, 2013].

Суть вейвлет-преобразования состоит в разложении сейсмической записи на волновые пакеты различных размеров, ориентации и положения [Никитин и др., 2013]. Существует большое количество вейвлетов, на основе формы сейсмического импульса выбирается подходящее преобразование. Полученные вейвлет-спектрограммы принципиально отличаются от обычных спектров Фурье тем, что дают четкую привязку спектра различных особенностей сигналов ко времени. Алгоритм адаптивного вычитания с использованием вейвлет-преобразований состоит в разложении сейсмической записи на волновые пакеты и последующим удалением пакетов, относящихся к волнам-помехам. Преимущество данного подхода заключается в независимости от динамических характеристик модели кратных. Однако на практике подобные преобразования требуют тяжелых вычислений, а также большого количества памяти для хранения весов каждого из пакетов.

В последнее время в обработке сейсмических данных широкой популярностью пользуются методы машинного обучения. С их помощью решают такие задачи, как подавление случайного шума [Zhu et al., 2019], пикировка первых вступлений [Loginov et al., 2019], подавление поверхностной волны [Zheng et al., 2022] и т. д. И как мы видим на практике использование машинного обучения зачастую приводит к положительным результатам.

В данной работе будет проверена концепция использования сверточной нейронной сети (СНС) для адаптивного вычитания кратных отраженных волн на синтетическом наборе данных. Использование СНС позволит решить основные проблемы стандартных подходов: 1) ручной подбор параметров фильтров; 2) низкая скорость процедуры адаптивного вычитания. Успешный результат в работе с синтетическим набором данных позволит в дальнейшем перейти к работе с реальными полевыми данными.

МЕТОД

Сверточные нейронные сети. Примечательно, что чаще всего в задачах обработки сейсмических сигналов применяются именно сверточные нейронные сети (СНС). Концепция СНС заключается в использовании сверточных фильтров с ядрами различных размеров и значений. Обучая нейронную сеть (НС), мы решаем задачу оптимизации, подбирая веса таким образом, чтобы результат применения НС наилучшим образом совпадал с правильным результатом с точки зрения функционала невязки (обучение с учителем).

Постановка задачи. Для корректной работы НС необходимо правильно поставить задачу. Для этого необходимо учесть ряд факторов:

- апробация подхода адаптивного вычитания с помощью НС на синтетическом наборе данных с последующим переходом к работе с реальным набором данных;
- выбор региона исследования;
- выбор этапа обработки сейсморазведочных данных, после которого будет использована процедура адаптивного вычитания с помощью НС;
- выбор входных и выходных параметров НС.

Перед тем как перейти к работе с реальными данными, необходимо проверить работоспособность метода на синтетических данных. Генерация синтетических данных будет рассмотрена ниже.

Несмотря на то что все кратные волны можно отнести к общей категории волн-помех, они отличаются по своей природе возникновения и траекториям. Так, например, в морской сейсморазведке применяют несколько процедур подавления кратных: 1) подавление кратных в водном слое; 2) подавление кратных от свободной поверхности. Однако в данной работе будет рассматриваться только наземная сейсморазведка.

По типу траектории кратные волны делят на полнократные, частично-кратные, внутрикратные (рис. 1). Несмотря на это после введения скоростного закона все типы кратных волн останутся не спрямленными, а это значит, что мы сможем их выделить в области Радона. Процедура подавления будет применяться после следующих этапов обработки: 1) введение статической поправки; 2) мьютинг; 3) подавление прямой волны; 4) подавление поверхностной волны; 5) подавление случайного шума; 6) введение кинематической поправки. Таким образом в сейсмической записи в основном останется только полезный сигнал и интересующие нас сейсмические помехи.

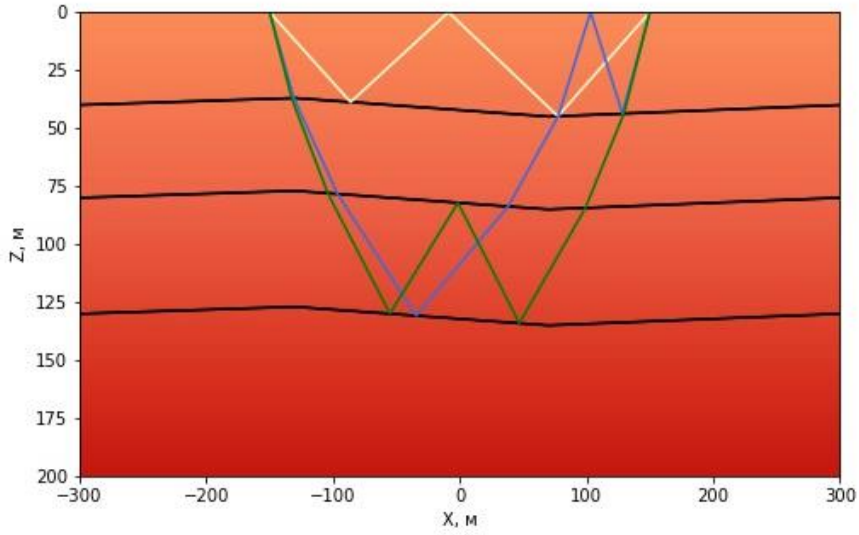

Рис. 1. Лучевая схема для разных типов кратных волн (желтый цвет – полнократная; синий цвет – частично-кратная; зеленый цвет – внутрикратная)

Входные данные для НС состоят из двух сейсмограмм общей глубинной точки (ОГТ): 1) полная сейсмическая запись; 2) модель кратных отраженных волн. На выходе НС мы получим три изображения: 1) очищенная сейсмограмма; 2) адаптированная модель кратных отраженных волн; 3) шум, который содержался в исходной сейсмической записи и модели кратных. Наличие шума обусловлено следующими причинами: 1) несмотря на то что предварительно уже были применены процедуры подавления различных шумов, эти процедуры не являются идеальными, а значит в сейсмической записи все еще остались артефакты; 2) наличие дополнительного изображения на выходе позволит повысить сходимость нейронной сети; 3) добавление случайного шума к синтетическим данным позволит увеличить размер обучающей и тестовой выборки.

Архитектура нейронной сети. Как уже говорилось выше, наибольшей популярностью для задач шумоподавления (обработка изображений) пользуются сверточные нейронные сети. За основу СНС, используемой в данной работе, была взята архитектура U-Net [Ronneberger et al., 2015]. Принцип работы данной модели СНС основан на последовательном использовании слоев свертки, пуллинга, а также остаточных связей. Сначала исходные данные преобразуются путем использования сверточных фильтров с различными ядрами свертки (построение карт признаков), затем размер преобразованных

данных уменьшается с помощью слоев пуллинга. После нескольких итераций понижения размерности данных используется обратная процедура восстановления изображения. Чтобы избежать потерю важных признаков, вводятся остаточные связи (skip connections), которые связывают изображения одинакового размера.

Архитектура состоит из 28 сверточных слоев, 4 слоев пуллинга, 4 слоев ап-семплинга, 4 пропускных связей (рис. 2). На вход подается трехмерный массив размера (400,800,2). Первая ось отвечает за номер трассы, вторая за номер отсчета по времени, третья за номер изображения. Каждый слой свертки возвращает *n*-ое количество карт признаков (количество фильтров). Количество фильтров для каждого слоя свертки соответствует:
4,8,8,16,16,16,32,32,32,64,64,64,128,128,128,64,64,64,32,32,32,16,16,16,8,8,8,4,3. Для всех слоев свертки кроме последнего используется функция активации ReLU. На последнем слое, используется функция активации tanh. На выходе СНС мы получаем три сейсмограммы исходного размера. В качестве функции потери используется среднеквадратичная невязка.

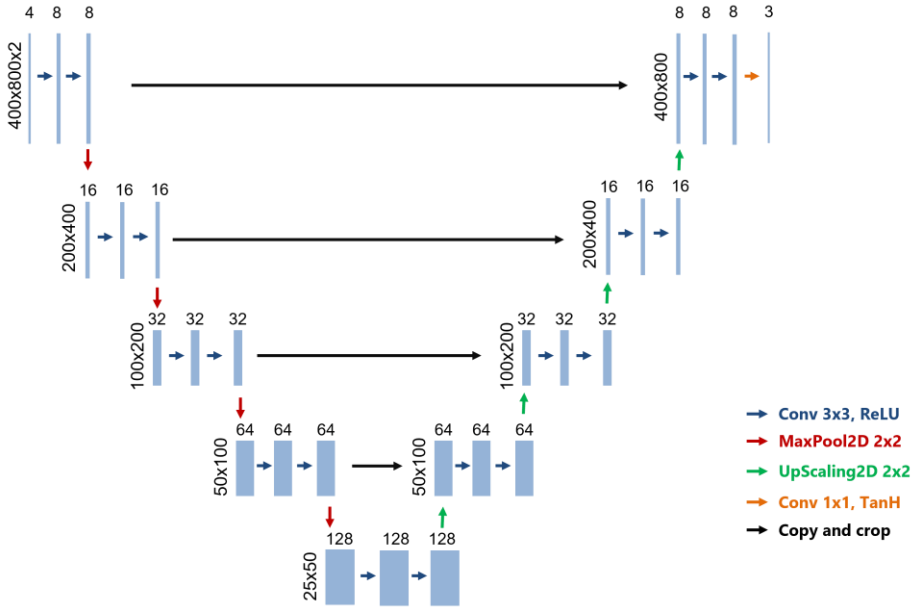

Рис. 2. Сверточный автоэнкодер с остаточными связями

Подготовка данных и обучение нейронной сети. Для генерации синтетического набора данных был использован метод моделирования, основанный на наложении одинаковой формы сигнала на годографы отраженных волн, полученных с помощью лучевого трассирования. Таким образом амплитуда сигнала остается постоянной для каждой волновой формы. Глубинно-скоростная модель представляет собой совокупность однородных слоев с криволинейными границами между ними (рис. 3). Для линейного профиля было смоделировано 284 сейсмограммы с длиной записи 4 с (шаг дискретизации 8 мс) и количеством трасс равным 322, максимальное удаление 8000 м.

Для обучения НС было предложено использовать одну сейсмограмму из набора. Для увеличения размера обучающей выборки, а также для повышения надежности работы НС к исходному набору данных был добавлен случайный Гауссов шум. Помимо этого, размер тренировочных данных был увеличен путем поворота сейсмограмм. Углы поворота принимали значения от 0 до 350 градусов включительно с шагом 10 градусов. В итоге было получено 36 изображений. Для построения модели кратных использовалась

быстрая библиотека высокоразрешающего гиперболического преобразования Радона [Nikitin et al., 2017]. Каждая сейсмограмма была нормирована на максимум по модулю. Так как размер смоделированных сейсмограмм меньше нужного размера, то по краям были добавлены нули. На рисунке 4 изображен пример входных данных НС.

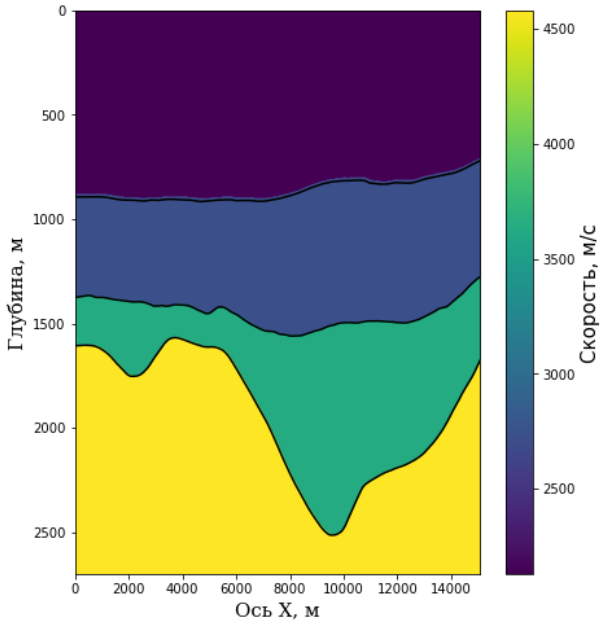

Рис. 3. Моделирование синтетических данных: глубинно-скоростная модель

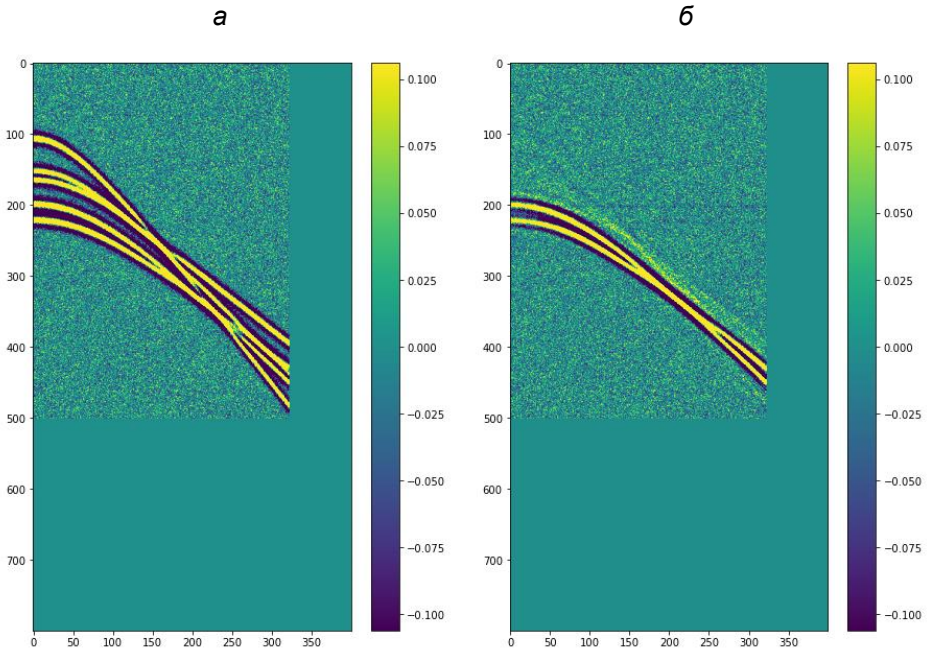

Рис. 4. Моделирование синтетических данных: пример входных данных для НС: *а* – исходная сейсмограмма; *б* – модель кратных отраженных волн

В качестве выходных данных для обучения НС, использовались предварительно смоделированные очищенная сейсмограмма, сейсмограмма кратных волн, сейсмограмма, содержащая в себе только Гауссов шум. Пример выходных данных изображен на рис. 5.

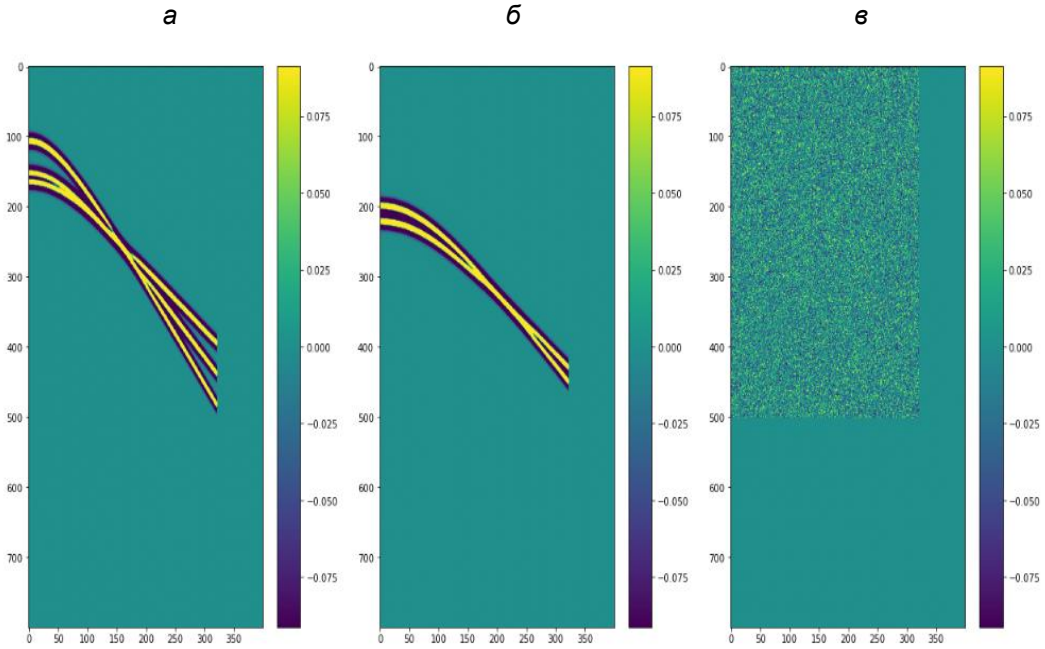

Рис. 5. Моделирование синтетических данных, пример выходных данных для НС: *а* – результат адаптивного вычитания; *б* – адаптированная модель кратных отраженных волн; *в* – сейсмограмма случайного шума

Обучалась НС в течение 1500 эпох. Размер валидационной выборки составил три изображения (что составляет 8.3 % от размера обучающей выборки). Кривая обучения изображена на рис. 6.

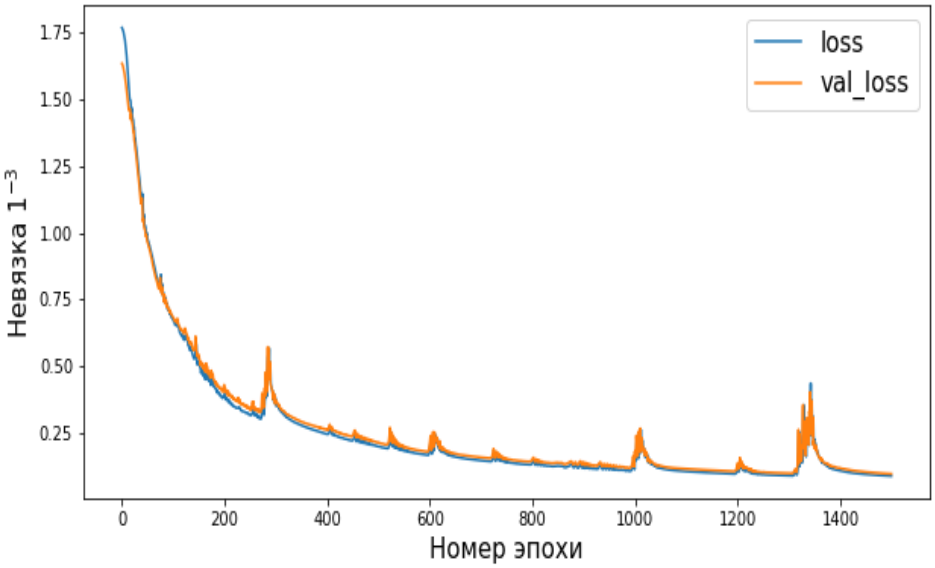

Рис. 6. Обучение НС: кривая обучения: синяя кривая – значение функционала невязки для обучающего набора данных; оранжевая кривая – значение функционала невязки для валидационной выборки

Тестирование нейронной сети. Для тестирования НС использовалось 283 предварительно смоделированных сейсмограмм. Для каждой из сейсмограмм был добавлен случайный Гауссов шум. Как видно на рис. 7, *а*, модель кратных отраженных волн, полученная с помощью высокоразрешающего преобразования Радона, не является идеальной. Однако с помощью НС удалось достигнуть разницы среднеквадратичных амплитуд равной 1.5 %.

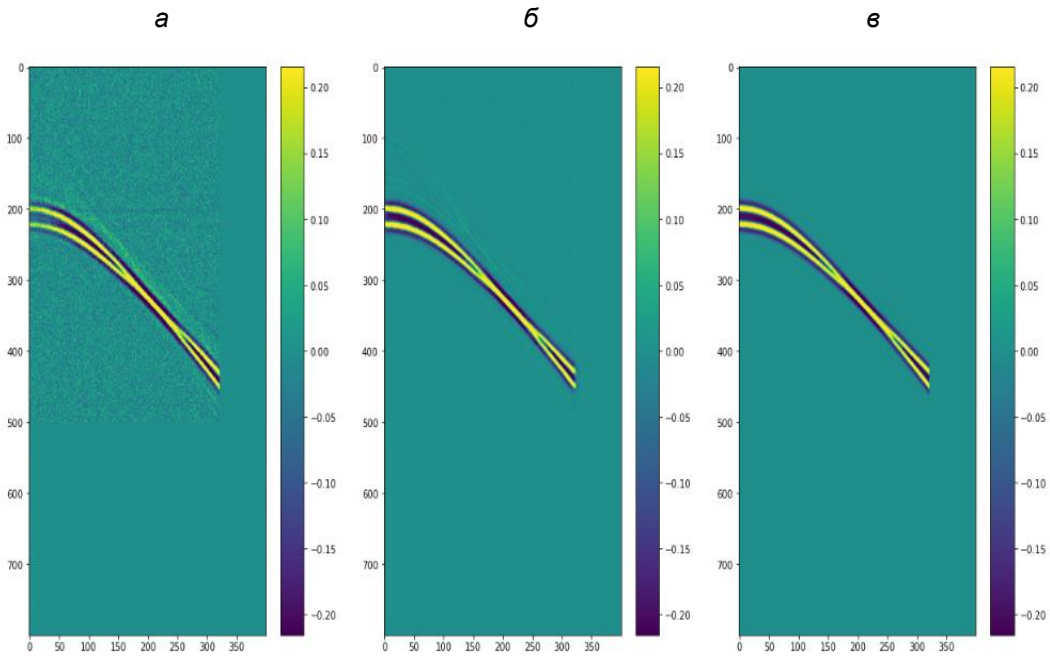

Рис.7. Тестирование работы НС: *а* – исходная модель кратных отраженных волн; *б* – адаптированная модель кратных отраженных волн; *в* – идеальная сейсмограмма кратных

Одна из главных проблем, возникающая при обучении НС, является проблема переобучения. Нужно проверить была ли НС обучена на адаптацию модели кратных или она научилась адаптировать только кратные волны, находящиеся в определенном месте. Что если бы кратные волны имели нормальные времена прихода – t_0, удаленные друг от друга? Как видно на рис. 8, НС справляется и с подобной моделью кратных отраженных волн.

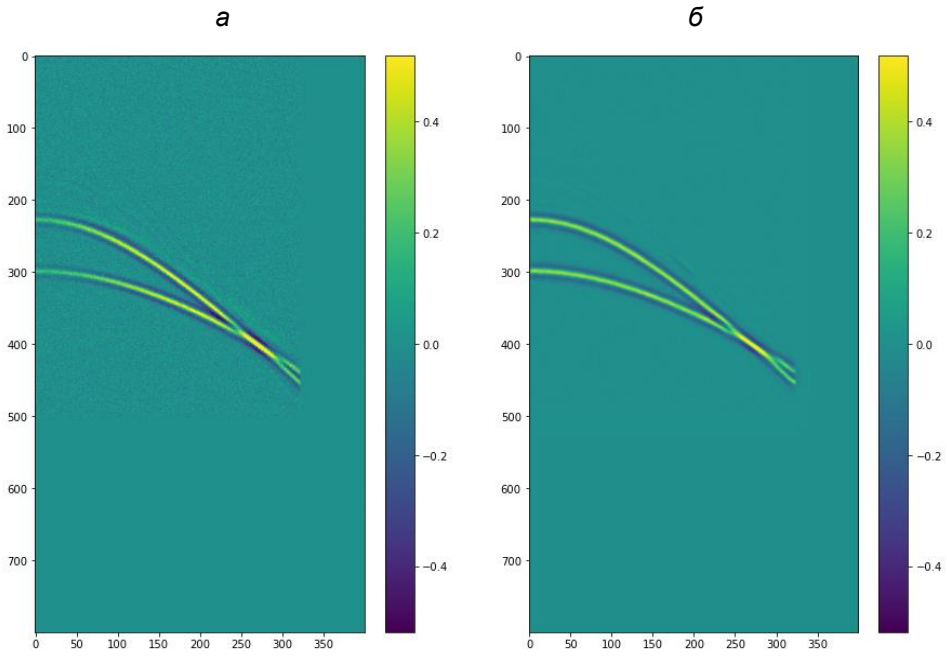

Рис. 8. Тестирование работы НС на новых данных: *а* – исходная модель кратных отраженных волн; *б* – адаптированная модель кратных отраженных волн

Рассмотрим случай присутствия целевого сигнала в модели кратных отраженных волн. Протестируем работу НС, подав на вход модель кратных отраженных волн, содержащую в себе остатки

целевого сигнала (рис. 9, *а*). Как мы видим на рис. 9, *б* НС пытается адаптировать артефакты целевого сигнала. Подобные результаты говорят о том, что НС была обучена именно на адаптацию сигнала, и не имеет значения присутствуют в записи какие-то конкретные кратные волны или целевой сигнал.

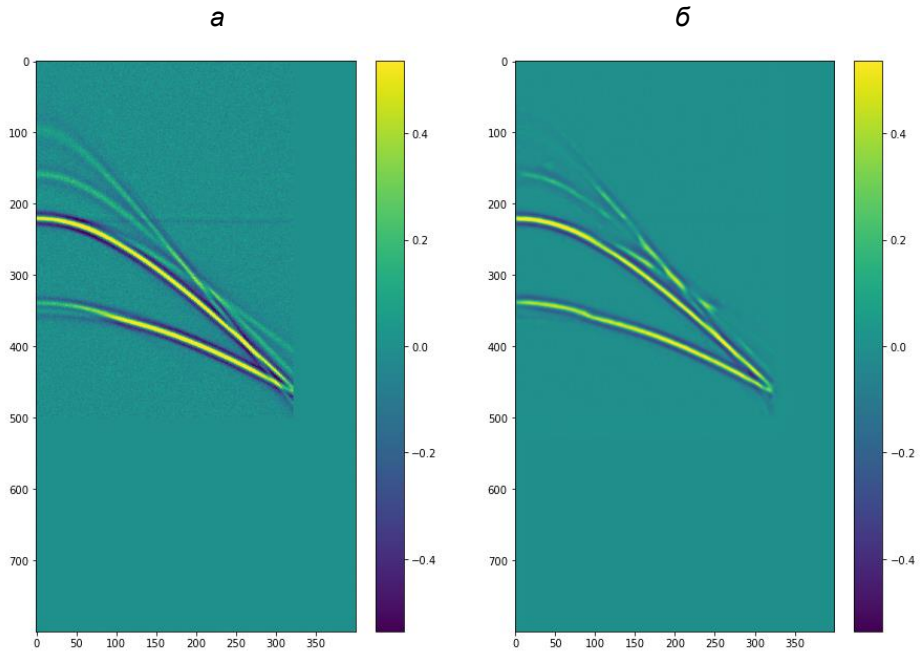

Рис. 9. Тестирование работы НС на некондиционных данных: *а* – исходная модель кратных отраженных волн; *б* – адаптированная модель кратных отраженных волн

Для наглядности работы НС давайте посмотрим на исходный и результирующий временные разрезы, изображенные на рис. 10. Как видно на этом рисунке с помощью НС удалось подавить ложные горизонты. При этом прослеживаются две проблемные зоны в районе 230 трассы на временах 1.7 и 2.8 с соответственно. Однако подобные проблемные зоны связаны с некорректностью модели кратных.

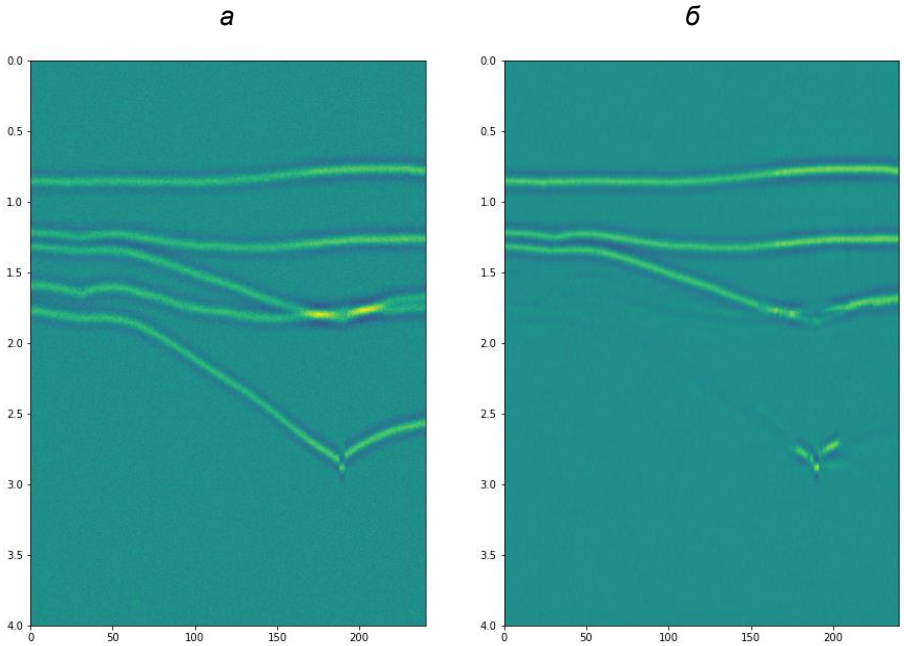

Рис. 10. Тестирование работы НС на общем наборе данных: *а* – исходный временной разрез; *б* – результирующий временной разрез

ВЫВОДЫ

Для решения задачи адаптивного вычитания была использована сверточная нейронная сеть. Разработанная структура СНС аналогична структуре U-Net. В качестве аналога остаточного шума после процедур предварительной обработки к сейсмической записи был добавлен случайный Гауссов шум. Также была использована процедура поворота данных путем умножения на матрицу поворота. Подобные процедуры позволили увеличить размер обучающей выборки, повысить гибкость работы СНС, а также уменьшить риск переобучения НС.

Наличие остаточных целевых волн в модели кратных приводит к подавлению целевого сигнала, что говорит о чувствительности СНС к модели кратных. Также подобный результат говорит о том, что СНС не была обучена на подавление двух определенных кратных отраженных волн, и она пытается адаптировать ту модель кратных отраженных волн, которая была подана на вход.

Использование обученной СНС показало хороший результат для адаптивного вычитания кратных отраженных волн на синтетическом наборе данных. Подобный результат позволяет в дальнейшем перейти к работе с реальными полевыми данными.

БЛАГОДАРНОСТИ

Разработка алгоритма адаптивного вычитания кратных отраженных волн осуществлялась при поддержке исследовательского проекта FSUS-2022-0019.

Тестирование работы алгоритма осуществлялось при поддержке исследовательского проекта FWZZ-2022-0017.

ЛИТЕРАТУРА

Боганик Г.Н., Гурвич И.И. Сейсморазведка. – Тверь: АИС, 2006. – 743 с

Никитин В.В., Дучков А.А., Романенко А.А., Андерссон Ф. Параллельный алгоритм разложения функций по волновым пакетам для GPU и его применение в геофизике // Вестник НГУ. Серия: Информационные технологии. – 2013. – № 11 (1). – С. 93–104.

Chen W., Yang L., Wang H., Chen Y. Fast high-resolution hyperbolic radon transform // IEEE Transactions on Geoscience and Remote Sensing. – 2021. – Vol. 60. – P. 1–10, doi: 10.1109/TGRS.2021.3084612.

Hampson D. Inverse velocity stacking for multiple elimination // Journal of the Canadian Society of Exploration Geophysicists. – 1986. – P. 44–55.

Loginov G., Duchkov A., Litvichenko D., Alyamkin S. The first-break detection for real seismic data with use of convolutional neural network // 81st EAGE Conference and Exhibition 2019. – 2019. – Vol. 2019 (1). – P. 1–5, doi: 10.3997/2214-4609.201901614.

Neelamani R., Baumstein A., Ross W.S. Adaptive subtraction using complex-valued curvelet transforms // Geophysics. – 2010. – Vol. 75 (4) – P. V51–V60, doi: 10.1190/1.3453425.

Nikitin V.V., Anderson F., Carlsson M., Duchkov A.A. Fast hyperbolic Radon transform represented as convolutions in log-polar coordinates // Computers & Geosciences. – 2017. – Vol. 105. – P. 21–33, doi: 10.1016/j.cageo.2017.04.013.

Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical image computing and computer-assisted intervention. – Springer, Cham, 2015. – P. 234–241.

Verschuur D.J. Seismic multiple removal techniques: past, present and future. – EAGE Publications, Houten, 2013. – 300 p.

Yilmaz Ö. Seismic data analysis: Processing, inversion, and interpretation of seismic data. – SEG, 2001. – 2065 p., doi: 10.1190/1.9781560801580.

Zheng Y., He D.K., Hou J., Feng X. Surface wave suppressing and decomposition using deep neural networks // 83rd EAGE Annual Conference & Exhibition. – 2022. – Vol. 2022 (1). – P. 1–5.

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.

REFERENCES

Boganik G.N., Gurvich I.I. Seismic prospecting [in Russian]. – AIS, Tver, 2006. – 743 p.

Nikitin V.V., Duchkov A.A., Romanenko A.A., Andersson F. Parallel algorithm for the expansion of functions in wave packets for GPU and its application in geophysics // NSU Bulletin. Series: Information Technology. – 2013. – Vol. 11 (1) – P. 93–104.

Chen W., Yang L., Wang H., Chen Y. Fast high-resolution hyperbolic radon transform // IEEE Transactions on Geoscience and Remote Sensing. – 2021. – Vol. 60. – P. 1–10, doi: 10.1109/TGRS.2021.3084612.

Hampson D. Inverse velocity stacking for multiple elimination // Journal of the Canadian Society of Exploration Geophysicists. – 1986. – P. 44–55.

Loginov G., Duchkov A., Litvichenko D., Alyamkin S. The first-break detection for real seismic data with use of convolutional neural network // 81st EAGE Conference and Exhibition 2019. – 2019. – Vol. 2019 (1). – P. 1–5, doi: 10.3997/2214-4609.201901614.

Neelamani R., Baumstein A., Ross W.S. Adaptive subtraction using complex-valued curvelet transforms // Geophysics. – 2010. – Vol. 75 (4) – P. V51–V60, doi: 10.1190/1.3453425.

Nikitin V.V., Anderson F., Carlsson M., Duchkov A.A. Fast hyperbolic Radon transform represented as convolutions in log-polar coordinates // Computers & Geosciences. – 2017. – Vol. 105. – P. 21–33, doi: 10.1016/j.cageo.2017.04.013.

Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical image computing and computer-assisted intervention. – Springer, Cham, 2015. – P. 234–241.

Verschuur D.J. Seismic multiple removal techniques: past, present and future. – EAGE Publications, Houten, 2013. – 300 p.

Yilmaz Ö. Seismic data analysis: Processing, inversion, and interpretation of seismic data. – SEG, 2001. – 2065 p., doi: 10.1190/1.9781560801580.

Zheng Y., He D.K., Hou J., Feng X. Surface wave suppressing and decomposition using deep neural networks // 83rd EAGE Annual Conference & Exhibition. – 2022. – Vol. 2022 (1). – P. 1–5.

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

КАМАШЕВ Александр Максимович – сотрудник лаборатории динамических проблем Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: разложение сейсмических изображений по волновым пакетам, методы подавления кратных отраженных волн, методы решения прямой задачи сейсморазведки.

ДУЧКОВ Антон Альбертович – кандидат физико-математических наук, заведующий лабораторией динамических проблем сейсмики, заместитель директора по научной работе Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: сейсмическая миграция; регуляризация сейсмических данных с помощью Гауссовских волновых пакетов, микросейсмический мониторинг гидроразрыва.

Статья поступила 30 января 2023,
принята к печати 28 марта 2023