

ПРИМЕР ПРИМЕНЕНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ОБРАБОТКЕ РЕАЛЬНЫХ ДАННЫХ 3D СЕЙСМОРАЗВЕДКИ

Георгий Николаевич Логинов

Новосибирский национальный исследовательский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова, 1, ассистент кафедры геофизики; Институт нефтегазовой геологии и геофизики им. А. А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, пр. Академика Коптюга, 3, научный сотрудник, e-mail: loginovgeorgy@gmail.com

Антон Альбертович Дучков

Новосибирский национальный исследовательский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова, 1, доцент кафедры геофизики; Институт нефтегазовой геологии и геофизики им. А. А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, пр. Академика Коптюга, 3, зав. лабораторией, e-mail: loginovgeorgy@gmail.com

Дмитрий Александрович Литвиченко

ООО «ГАЗПРОМНЕФТЬ НТЦ», 625048, Россия, г. Тюмень, ул. 50 лет Октября, 14, руководитель направления по моделированию сейсмоданных, e-mail: litvichenko.da@gazpromneft-ntc.ru

Сергей Анатольевич Алямкин

ООО «Экспасофт», 630090, Россия, г. Новосибирск, ул. Николаева, 11, руководитель проектов, e-mail: s.alyamkin@expasoft.ru

В работе рассматривается применение сверточной нейронной сети для детектирования первых вступлений для реального набора 3D сейсмических данных объемом более 4,5 млн. трасс. Детектирование первого вступления для каждой трассы осуществляется независимо. Ошибка между оригинальным и прогнозируемым первыми вступлениями составляет не более 3 выборки для 95% данных. Контроль качества выполнен путем расчета статических поправок и стеков, что показало эффективность предлагаемого подхода.

Ключевые слова: времена первых вступлений, сверточные нейронные сети, обработка сигналов, верхняя часть разреза.

THE CASE STUDY OF CONVOLUTION NEURAL NETWORKS APPLICATION FOR THE PROCESSING OF REAL 3D SEISMIC DATA

Georgy N. Loginov

Novosibirsk National Research State University, 1, Pirogova St., Novosibirsk, 630073, Russia, Associate of the Geophysics Department; Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 3, Prospect Akademik Koptyug St., Novosibirsk, 630090, Russia, Researcher, e-mail: LoginovGN@ipgg.sbras.ru

Anton A. Duchkov

Novosibirsk National Research State University, 1, Pirogova St., Novosibirsk, 630073, Russia, Associate Professor of the Geophysics Department; Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 3, Prospect Akademik Koptyug St., Novosibirsk, 630090, Russia, Head of Laboratory, e-mail: LoginovGN@ipgg.sbras.ru

Dmitry A. Litvichenko

LLC GAZPROMNEFT NTC, 14, 50 years of October St., Tyumen, 625048, Russia, Head of Seismic Data Modeling, e-mail: litvichenko.da@gazpromneft-ntc.ru

Sergey A. Alyamkin

LTD Expasoft, 11, Nikolaeva St., Novosibirsk, 630090, Russia, Project Manager, e-mail: s.alyamkin@expasoft.ru

The paper considers the use of a convolution neural network for detecting first arrivals for a real set of 3D seismic data with more than 4.5 million traces. Detection of the first breaks for each trace is carried out independently. The error between the original and the predicted first breaks is no more than 3 samples for 95% of the data. Quality control is performed by calculating static corrections and seismic stacks, which showed the effectiveness of the proposed approach.

Key words: first breaks, convolution neural network, nearsurface velocity model.

Времена первых вступлений являются ключевыми данными для восстановления модели верхней части разреза и расчета статических поправок. Статические поправки в значительной степени зависят от надежности выделения первых вступлений и влияют на эффективность работы методов сейсмической обработки, основанных на принципах отражения и преломления [4]. Традиционно, для построения скоростной модели используется рефракционная томография на основе первых вступлений. Ввиду большого объема сейсмических данных, процедура детектирования первых вступлений, помимо точности, должна быть быстрой и автоматизированной [6]. Волновое поле первых вступлений обычно включает сигналы прямых, головных и преломленных волн. На точность обнаружения первых вступлений влияет качество сейсмических записей и сложность скоростной модели. Из-за сложности волнового поля результаты любого алгоритма детектирования времен вступлений будут иметь неопределенность, которая может быть устранена только при дальнейших процедурах инверсии [1].

Большинство алгоритмов детектирования основаны на анализе энергии сигнала в скользящем окне [2]. В [3] предложили полносвязную нейронную сеть с использованием набора детектирующих функций, полученных традиционными алгоритмами детектирования. В [5] была предложена сверточная нейронная сеть для детектирования времен вступлений на сейсмограммах ОГТ. В [7] авторы предложили классифицировать волновые формы сейсмологических и микросейсмических событий при помощи сверточной нейронной сети. Большинство предложенных подходов основаны на глубоком обучении, что подразумевает использование большого объема данных для обучения и большое количество скрытых слоев в нейронной сети.

В данной работе рассматривается применение сверточной нейронной сети для выбора детектирования времен первых вступлений на реальном 3D наборе сейсмических данных. Мы стремились использовать простую архитектуру нейронной сети, которая была бы легковоспроизводимой. Общий объем набора рассматриваемых данных составляет около 4,5 миллионов трасс. Район сейсми-

ческих наблюдений осложнен сильными неоднородностями, связанными с наличием зон обводнения, многолетних мерзлых пород и оттаивания. Данные факторы осложняют процесс интерпретации волнового поля. В некоторых районах многолетних мерзлых пород наблюдается эффект выпадения слоя. Кроме этого, район наблюдений включает в себя разные превышения рельефа, в том числе поймы рек. Чтобы оценить эффективность предлагаемого подхода, по выделенным временам вступлений были рассчитаны статические поправки и стеки.

Использование свертки в качестве ядра обучения нейронной сети продиктовано предположением, что сейсмическая трасса может рассматриваться как свертка исходного сигнала с функцией отражения. Годографы первых вступлений могут быть сильно осложнены ввиду строения скоростной модели верхней части разреза. Предлагаемый подход предполагает детектирование первых вступлений для каждой сейсмической трассы независимо, чтобы сохранить информацию о сложном строении ВЧР. Далее в этом разделе мы обсудим основные этапы разработки оптимальной модели CNN: обработка и разметка входных данных, выбор архитектуры и функции потерь, введение процедур регуляризации, обработка выходных данных CNN.

Исходная разметка данных представляет собой двоичную матрицу, число строк которой соответствует количеству отсчетов сейсмической трассы, а количество строк – количеству классов. Элемент матрицы равен 1, где отсчет трассы принадлежит определенному классу. Стандартный подход машинного обучения предполагает введение двух классов (бинарная классификация): первое вступление и не первое вступление. Бинарная классификация приводит к сильному дисбалансу классов. Стандартным методом для преодоления этой проблемы является взвешивание классов в функции потерь во время обучения CNN. Однако, такая стратегия потребовала бы дополнительного экспериментального исследования оптимальных весов. Мы предлагаем альтернативный подход и рассмотрим 3 класса: шум, первое вступление и сигнал. В соответствии с широким диапазоном трасс с разными смещениями, используемыми для обучения CNN, мы имеем хороший баланс как минимум двух классов: шум и сигнал. Результаты численных экспериментов показали, что такой подход обеспечивает более надежное обнаружение первого вступления. Поскольку классы сбалансированы, мы используем традиционную для таких задач функцию потерь – кросс-энтропия в ее классическом представлении.

Обработка сейсмических данных может включать в себя десятки процедур для повышения уровня сигнала к шуму. В основном это полосовая фильтрация, коррекция усиления, суммирование трасс, коррекция статики и т. д. Мы стремимся минимизировать набор процедур обработки для обнаружения первого вступления. Таким образом, в следующих разделах мы подразумеваем только вычитания среднего значения по трассе (detrend) и нормировку на разницу между минимальным и максимальным значением по трассе (нормализация). Поскольку обработанные значениям трассы принадлежат интервалу $(-1; 1)$, обучение CNN упрощается и скорость сходимости увеличивается. Кроме того, пред-

лагаемая обработка оказывает слабое влияние на параметры волнового поля, что позволяет избежать возникновения артефактов.

В большинстве случаев модель CNN может быть разработана только при экспериментальном тестировании различных архитектур. Термин «архитектура» в основном подразумевает набор скрытых слоев. В этой статье мы рассмотрим следующие процедуры слоя: свертка, нормализация батча, активация и исключение. Каждая процедура имеет набор своих гиперпараметров, выбранных в ходе численных экспериментов. Параметры свертки: количество фильтров и их длина. Процедура нормализации батча используется для обеспечения нулевого среднего и единичной дисперсии входных данных. Для скрытых слоев CNN рекомендуется использовать функцию активации ReLU (rectified linear unit).

Оценка модели и контроль качества. Размер выходных данных CNN совпадает с исходной матрицей разметки, число отсчетов совпадает с числом отсчетов сейсмотрассы. Элементы матрицы – это значение вероятности, что отражает принадлежность отсчета трассы к одному из трех классов: шум, первое вступление, сигнал. В данном контексте первое вступление – номер отсчета с максимальной вероятностью для матричного столбца, который принадлежит соответствующему классу. Для оценки точности предложенного подхода мы измеряем среднюю абсолютную ошибку между оригинальными и предсказанными первыми вступлениями. Общепринято, что проблема детектирования первых вступления имеет большую неопределенность. Кроме того, исходная разметка данных по оригинальным временам вступлений может содержать ошибки. Нулевая ошибка между оригинальными и прогнозируемыми временами вступлениями не будет точно описывать производительность предлагаемого подхода. Таким образом, мы устанавливаем окно допустимой разности между оригинальными и прогнозируемым временами и рассчитываем процент ошибок, которые принадлежат этому окну. Наконец, мы рассчитали статические поправки по прогнозируемым временам и выполнили суммирование данных, чтобы проиллюстрировать производительность предлагаемого подхода.

Набор данных для обучения представляет собой реальные сейсморазведочные 3D данные с источником типа взрыв, удалениями до 1200 м, 30000 точек источников на площади 1000 км. Общее количество трасс составляет около 4,5 миллионов с шагом дискретизации 2 мс. Оригинальные времена вступлений были получены с использованием традиционного промышленного программного обеспечения. Оригинальные времена первых вступлений были проверены внутренними показателями контроля качества и успешно применены в процессе дальнейшей обработки: рефракционная томография, статические поправки, суммирование, миграция и т. д. Мы стремились разработать модель CNN, которая была бы пригодна для различных наборов сейсмических данных, по крайней мере для того же типа источника и аналогичных условий наблюдений. Мы стремились разработать модель CNN с минимальным набором слоев для поддержки возможности дообучения и воспроизведения CNN.

Мы протестировали различный размер набора данных для обучения и количество слоев CNN. Обученная CNN была оценена по полному набору данных (4,5 миллиона трасс). Окончательная архитектура модели CNN представлена в табл. 1. Скрытые слои CNN содержат набор операций. Сначала применяется свертка с 32 фильтрами длиной 32 отсчета. К результатам свертки применяется функция активации ReLU, которая выбрана экспериментально. Затем применяется нормализация батча и исключение. Выходной слой CNN представляет собой свертку с 3 фильтрами с функцией активации sigmoid, которая обеспечивает классификацию отсчетов входной трассы на 3 класса: шум, первое вступление и сигнал. Производительность обученной CNN с различным количеством слоев и размером обучающей выборки представлены в табл. 2, где показан процент предсказанных первых вступлений с абсолютной ошибкой не более 3 отсчетов. Из таблицы видно, что, начиная с 4 скрытых слоев и 5 тысяч примеров, точность практически стабильна.

Таблица 1

Предлагаемая архитектура сверточной нейронной сети,
где n – число отсчетов входных трасс, k – количество скрытых слоев

№ слоя	Процедура	Размер входных данных	Размер выходных данных
1..k	Свертка (32 фильтра, длиной 32 отсчета) Активационная функция ReLU Нормализация батча Исключение (с порогом 0.5)	$n \times 1$	$n \times 32$
k+1	Свертка (3 фильтра, длиной 32 отсчета) Активационная функция sigmoid	$n \times 32$	$n \times 3$

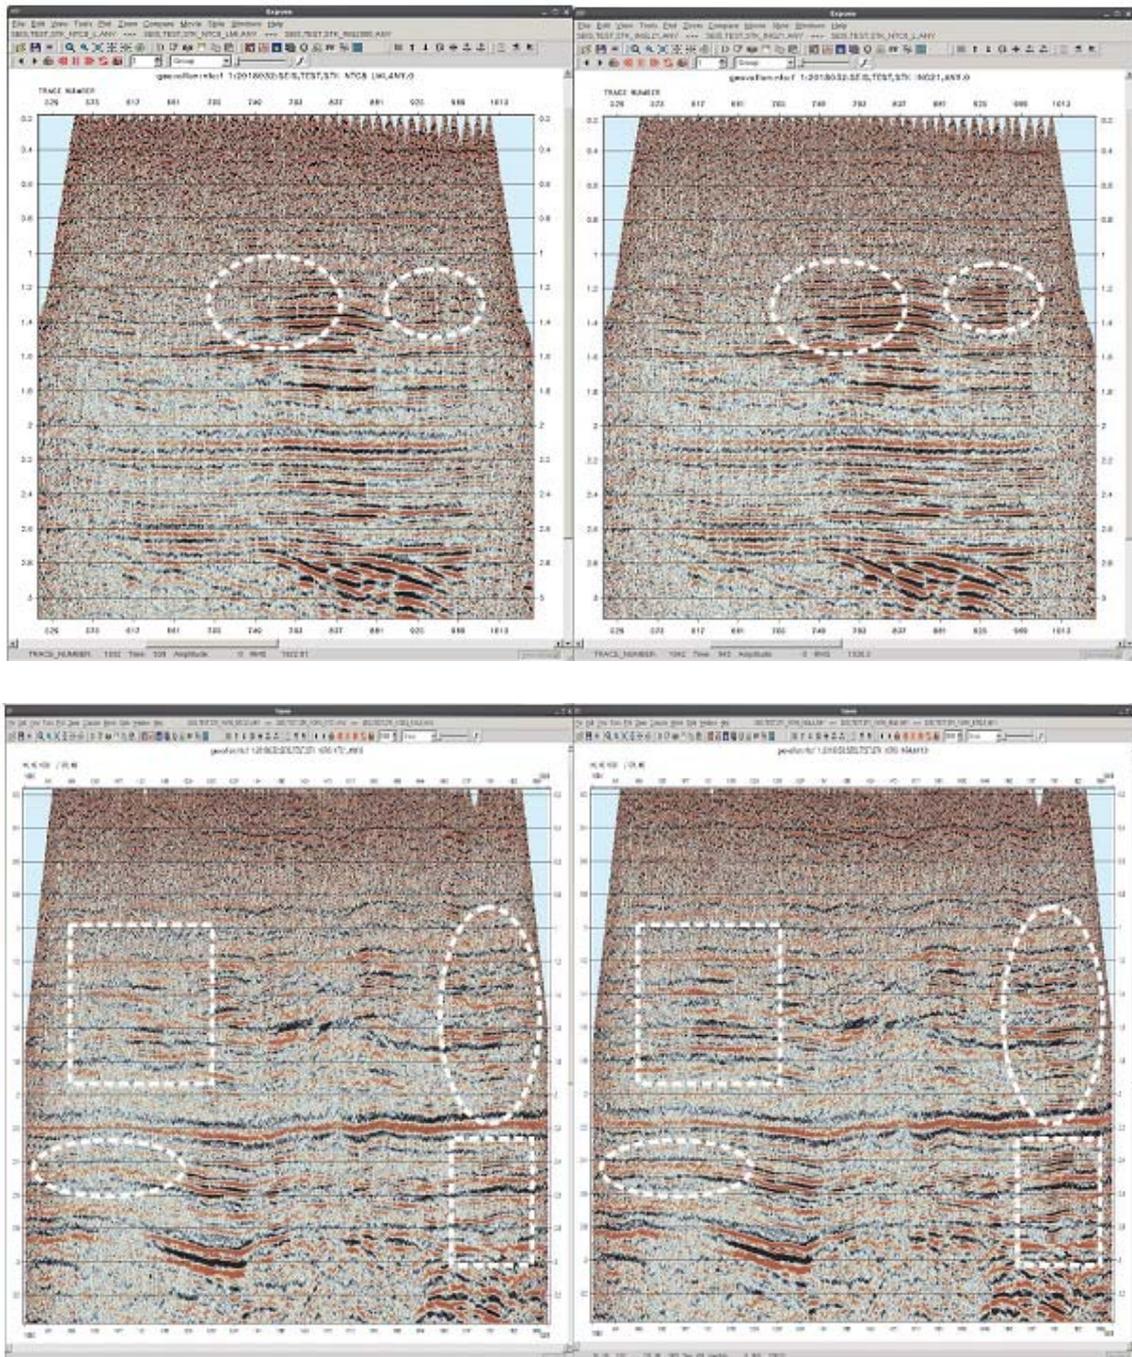
Таблица 2

Сравнение точности работы обученной нейронной сети для разного объема обучающей выборки (по горизонтали) и числа скрытых слоев (по вертикали)

Число слоев	Размер обучающей выборки				
	5000	10 000	25 000	50 000	100 000
1	83,5	83,6	N/A	N/A	N/A
2	91,0	91,3	N/A	N/A	N/A
3	93,0	94,7	N/A	N/A	N/A
4	94,3	95,0	95,3	95,6	96,0
5	94,5	95,7	95,7	95,9	96,1
6	94,1	95,8	95,7	96,0	96,0
7	95,3	95,1	95,7	95,9	95,8

Наиболее адекватным способом контроля качества является расчет статистических поправок и суммирование данных. На рисунке представлены стеки сейсмических данных: слева – стек с оригинальными временами вступлений,

справа – по результатам CNN; верхняя панель представляет результаты для тренировочного набора данных, а нижняя – для тестового набора. Можно увидеть, что стеки, рассчитанные по предсказанным временам вступлений, имеют более сглаженные горизонты, более высокие контрасты отражателей и больше деталей. Этот пример иллюстрирует применимость предложенного подхода и доказывает успешное применение на реальных сейсмических данных.



Стеки данных, рассчитанные с различными статическими поправками: слева – по оригинальным первым вступлениям; справа – по предсказанным. Белые фигуры подчеркивают наиболее отличные особенности стека. Верхняя панель – для тренировочного сейсмического набора; нижняя – тестовый набор

Предложен алгоритм выделения времен первых вступлений, основанный на сверточной нейронной сети. Были протестированы глубина нейронной сети и размер набора данных для обучения. В результате экспериментов показано, что 4 скрытых слоя и набор данных из 5 тысяч примеров достаточно для определения первых вступлений с достаточным качеством. Предложенный подход был апробирован на реальных данных 3D сейсморазведки объемом более 4,5 млн. сейсмотрасс. Тестирование показало, что ошибка между оригинальными и предсказанными первыми вступлениями составляет не более 3 отсчетов для 95% набора данных. Финальный контроль качества результатов был выполнен путем расчета статических поправок и сейсмических стеков, что показало успешную применимость предлагаемого подхода.

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 18-35-00412. Авторы благодарят ООО «ГАЗПРОМНЕФТЬ - НТЦ» за возможность опробовать предлагаемый подход на реальных данных и опубликовать результаты исследования.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Akram J., Eaton D.W. A review and appraisal of arrival-time picking methods for downhole microseismic data // *Geophysics*. – 2016. – Т. 81. – №. 2. – С. KS71-KS91.
2. Allen R.V. Automatic earthquake recognition and timing from single traces // *Bulletin of the Seismological Society of America*. – 1978. – Т. 68. – №. 5. – P. 1521-1532.
3. Maity D., Aminzadeh F., Karrenbach M. Novel hybrid artificial neural network based autopicking workflow for passive seismic data // *Geophysical Prospecting*. – 2014. – Т. 62. – №. 4. – С. 834-847.
4. Sabbione, J.I., Velis, D. Automatic first-breaks picking: New strategies and algorithms // *Geophysics*. – 2010. – Vol. 75(4). – P. V67–V76.
5. Yilmaz Ö. *Seismic data analysis: Processing, inversion, and interpretation of seismic data*. – Tulsa, USA: Society of exploration geophysicists, 2001 – 549 p.
6. Seismic waveform classification and first-break picking using convolution neural networks / S. Yuan, J. Liu, S. Wang, T. Wang, P. Shi // *IEEE Geoscience and Remote Sensing Letters*. – 2018. – Т. 15. – №. 2. – P. 272-276.
7. Sabbione J.I., Velis D. Automatic first-breaks picking: New strategies and algorithms // *Geophysics*. – 2010. – Т. 75. – №. 4. – С. V67-V76.
8. Zhu W., Beroza G.C. PhaseNet: a deep-neural-network-based seismic arrival-time picking method // *Geophysical Journal International*. – 2018. – Т. 216. – №. 1. – С. 261-273.

© Г. Н. Логинов, А. А. Дучков, Д. А. Литвиченко, С. А. Алямкин, 2019