



ОБРАБОТКА ДАННЫХ БОКОВОГО СКАНИРУЮЩЕГО КАРТАЖА В ПРОЦЕССЕ БУРЕНИЯ С ПРИМЕНЕНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

К.Н. Даниловский, Г.Н. Логинов

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

В статье рассматривается новый подход к обработке данных бокового сканирующего каротажа в процессе бурения на основе комбинации трехмерного численного моделирования и сверточных нейронных сетей. Подготовлен набор данных для обучения нейронных сетей, содержащий реалистичные синтетические имиджи удельного электрического сопротивления и разметку границ геоэлектрических слоев, учитывающую истинные значения параметров их пространственной ориентации. С применением сверточных нейронных сетей разработаны и программно реализованы два алгоритма: подавления случайных помех и детектирования границ пластов на имиджах удельного электрического сопротивления. Разработанные алгоритмы позволяют оперативно и точно обрабатывать большие объемы данных, при этом, благодаря отсутствию в архитектурах нейронных сетей полносвязных слоев, возможна обработка имиджей удельного электрического сопротивления произвольной протяженности.

Геонавигация, боковой сканирующий каротаж, имидж удельного электрического сопротивления, искусственные нейронные сети, сверточные нейронные сети

LATERAL SCANNING LOGGING WHILE DRILLING DATA PROCESSING USING CONVOLUTIONAL NEURAL NETWORKS

K.N. Danilovskiy, G.N. Loginov

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

This article discusses a new approach to processing lateral scanning logging while drilling data based on a combination of three-dimensional numerical modeling and convolutional neural networks. We prepared dataset for training neural networks. Dataset contains realistic synthetic resistivity images and geoelectric layer boundary layouts, obtained based on true values of their spatial orientation parameters. Using convolutional neural networks two algorithms have been developed and programmatically implemented: suppression of random noise and detection of layer boundaries on the resistivity images. The developed algorithms allow fast and accurate processing of large amounts of data, while, due to the absence of full-connection layers in the neural networks' architectures, it is possible to process resistivity images of arbitrary length.

Geosteering, lateral scanning logging, resistivity image, artificial neural networks, convolutional neural networks

ВВЕДЕНИЕ

При наклонно-направленном бурении нефтяных скважин применяют геонавигацию – оперативную корректировку траектории для удержания скважины в пределах целевого нефтеносного пласта. Решение о корректировке траектории принимается непосредственно в процессе бурения по результатам интерпретации каротажных данных, получаемых в реальном времени от приборов, входящих в состав буровой колонны [Larsen et al., 2016; Даниловский и др., 2019].

В России широкое распространение приобретает новый отечественный комплекс приборов каротажа в процессе бурения «ЛУЧ-М» [Каюров и др., 2014; Глинских и др., 2017], разработанный на Научно-производственном предприятии геофизической аппаратуры «Луч» (НПП ГА «Луч», г. Новосибирск) совместно с Институтом нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН (ИНГГ СО РАН, г. Новосибирск). Наряду с зондами, выполняющими традиционные геофизические измерения, комплекс включает в себя первый отечественный прибор бокового сканирующего каротажа (БКС) в процессе бурения [Danilovskiy et al., 2018]. Интерпретация данных БКС является одним из передовых способов, используемых в мире при геонавигации наклонно-направленных нефтяных скважин.

Глубокие сверточные искусственные нейронные сети (ИНС) представляют собой особую разновидность алгоритмов машинного обучения, которые хорошо зарекомендовали себя при решении задач, связанных с обработкой сигналов и изображений, в том числе и в скважинной геофизике [Логинов, Петров, 2019; Danilovskiy et al., 2021]. Сверточные ИНС базируются на фундаментальных концепциях нейронных сетей и используют функцию свертки для передачи информации между слоями ИНС. Имиджи удельного электрического сопротивления (УЭС), получаемые в результате обработки измерений БКС, представляют собой, по сути, изображение электрических свойств среды вокруг скважины, поэтому применение сверточных ИНС для их обработки является весьма перспективным направлением.

В статье описывается способ создания набора данных для обучения ИНС на основе трехмерного численного моделирования измерений БКС с последующей их аугментацией. Полученный таким образом набор данных используется для обучения сверточных ИНС, применяемых для решения двух задач: подавления случайных помех и детектирования границ пластов на имиджах УЭС.

СОЗДАНИЕ НАБОРА ДАННЫХ ДЛЯ ОБУЧЕНИЯ ИНС

Одним из наиболее важных факторов, которые в недавнем времени сделали возможным широкое применение глубоких ИНС для решения различных научно-технических задач, является увеличение объемов данных, доступных для их обучения [Goodfellow et al., 2017]. Накопление большого количества скважинных геофизических данных, а также развитие методов численного моделирования сигналов геофизических приборов открывает возможности для применения алгоритмов, основанных на методах машинного обучения, при решении задач промысловой геофизики.

Для того чтобы ИНС могли качественно решать поставленные задачи, их необходимо обучить на наборе данных представительного объема, при этом одним из возможных подходов к его созданию является проведение масштабного численного моделирования. Недостаток такого подхода состоит в длительности процесса расчета сигналов БКС из-за трехмерной постановки задачи. Одно из возможных решений состоит в применении параллельных вычислений на высокопроизводительных устройствах (графических ускорителях и суперкомпьютерных кластерах). Другое возможное решение состоит в аугментации данных из обучающей выборки – создании дополнительных данных из уже имеющихся путем применения простых преобразований, не требующих значительных вычислительных ресурсов.

Аугментация увеличивает как объем, так и разнообразие данных, что является эффективной стратегией борьбы с переобучением ИНС [Krizhevsky et al., 2012].

Для создания обучающего набора данных алгоритм трехмерного численного моделирования измерений БКС [Глинских и др., 2018] адаптируется для расчета сигналов в геоэлектрических моделях, где скважина пересекает большое количество слоев с разноориентированными в пространстве границами. Двадцать случайно сгенерированных геоэлектрических моделей среды содержат от 14 до 96 слоев, при этом углы и азимуты падения границ в моделях меняются плавно по глубине скважины и варьируются, соответственно, от 0° до 89° и от 0° до 359° . УЭС слоев в моделях распределены логнормально и варьируются от 1 до 500 Ом·м. Полученные в результате численного моделирования синтетические сигналы (кажущиеся УЭС) затем логарифмируются, поскольку для обучения ИНС эффективнее использовать нормально распределенные величины.

Для минимизации времени вычислений расчеты сигналов БКС проводятся на кластере НКС-1П Сибирского суперкомпьютерного центра Института вычислительной математики и математической геофизики СО РАН (ССКЦ ИВМиМГ СО РАН, г. Новосибирск). По результатам расчетов получено более 2000 м синтетических имиджей УЭС в геоэлектрических моделях, суммарно состоящих из 700 геоэлектрических слоев. Все данные представлены с шагом дискретизации измерений по глубине 0.1 м в 16 азимутальных секторах. Для преобразования полученных данных в формат, пригодный для обучения ИНС, исходные синтетические имиджи и соответствующие им положения границ геоэлектрических слоев разделяются на интервалы малой протяженности (3–12 м). При этом 85 % полученной выборки используется для обучения, а 15 % – для тестирования работы ИНС.

Для расширения обучающей выборки к полученным в результате трехмерного численного моделирования имиджам УЭС применяется процедура аугментации [Danilovskiy et al., 2020]. В задачах, связанных с компьютерным зрением, аугментацию данных зачастую проводят при помощи простых преобразований исходных изображений: сдвигов, поворотов, масштабирования. Поскольку имиджи представляет собой панорамные изображения стенки скважины, наиболее естественным способом аугментации является применение операции последовательного кругового сдвига на один отсчет в азимутальном направлении. Таким образом, объем обучающего набора данных увеличивается в 16 раз (по числу азимутальных измерений), при этом не требуется значительных вычислительных ресурсов. Помимо кругового сдвига для расширения набора данных также возможно применение других преобразований (горизонтальных и вертикальных отражений, масштабирования). Полный процесс получения обучающего набора данных схематично показан на рис. 1.

Для того чтобы преобразовать синтетические имиджи УЭС в псевдопрактические применяется шум Перлина – математический алгоритм, использующийся для генерации текстур псевдослучайным методом, при этом не требующий серьезных вычислительных мощностей [Perlin, 1985].

Представленный подход к созданию обучающего набора данных позволяет получить реалистичные синтетические имиджи УЭС в геоэлектрических моделях, где скважина пересекает границы с любыми возможными параметрами (z , θ , φ), при этом для каждой границы известны их истинные значения. Применение аугментации позволяет значительно сократить время, необходимое для получения набора данных, достаточного для обучения глубоких ИНС. Полученный таким образом набор данных может быть адаптирован под конкретную задачу и используется далее для обучения сверточных ИНС, применяемых для решения двух задач: подавления случайных помех и поточечного детектирования геоэлектрических границ на имиджах УЭС.

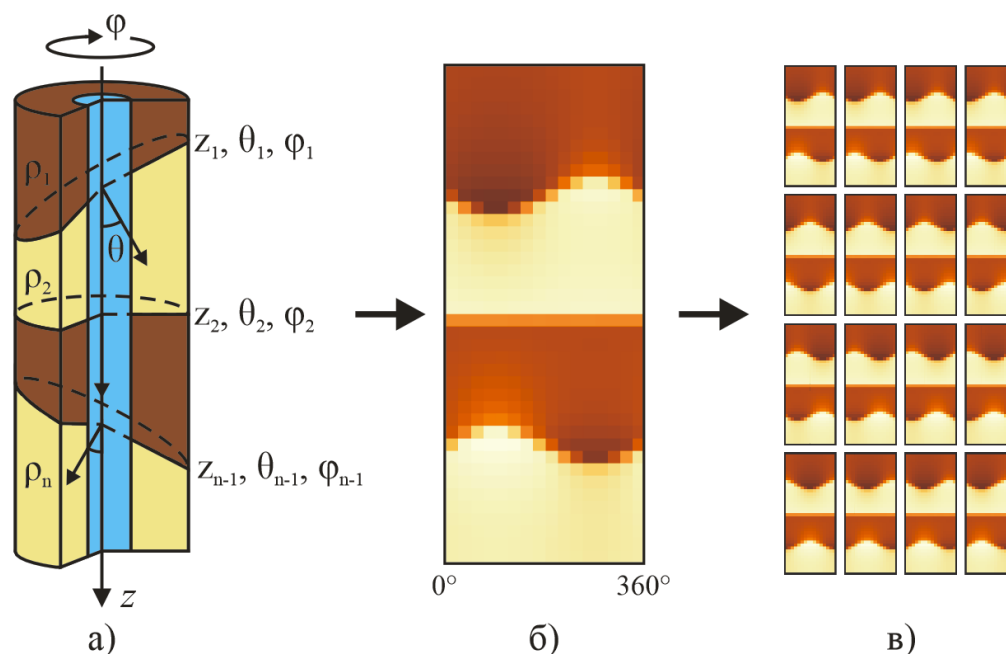


Рис. 1. Схема получения обучающего набора данных: а – геоэлектрическая модель, в которой рассчитываются сигналы прибора; б – имидж УЭС, полученный в результате трехмерного численного моделирования; в – имиджи УЭС, полученные в результате аугментации

ПОДАВЛЕНИЕ СЛУЧАЙНЫХ ПОМЕХ НА ИМИДЖАХ УЭС С ПРИМЕНЕНИЕМ СВЕРТОЧНОГО АВТОКОДИРОВЩИКА

Интерпретация имиджей УЭС осложняется наличием в измерениях случайных помех, обусловленных погрешностью измерения прибора. Традиционный подход к обработке имиджей УЭС подразумевает применение процедур фильтрации с использованием, например, медианного фильтра или фильтра Гаусса. Недостаток такого подхода состоит в том, что при фильтрации возможна потеря важной информации, содержащейся в исходных сигналах прибора. В то же время широкое развитие методов машинного обучения в последние годы позволяет строить более сложные фильтры с применением ИНС. В комбинации с численным моделированием сигналов БКС такой подход является перспективным, поскольку в качестве «ответов» ИНС может получать истинные незашумленные имиджи УЭС.

С учетом описанных выше проблем при помощи ИНС решается задача регрессии, где по входным зашумленным сигналам восстанавливаются истинные сигналы без шума. Зашумленный имидж УЭС произвольной длины подается на вход ИНС, проходит через ряд слоев, состоящих из сверточных фильтров или меняющих разрешение имиджа, а на выходе восстанавливается незашумленный имидж УЭС. Для обучения ИНС в качестве «ответов» используются синтетические имиджи УЭС, а в качестве входных данных – те же имиджи с добавлением нормально распределенного шума, дисперсия которого возрастает с увеличением кажущегося УЭС, что типично для гальванических методов.

В качестве архитектуры ИНС используется сверточный автокодировщик – ИНС, состоящая из двух частей: кодировщика и декодировщика (рис. 2). Разработанная ИНС включает входной слой, два скрытых сверточных слоя и один субдискретизирующий слой кодировщика, скрытый центральный сверточный слой, создающий сжатое представление исходного имиджа УЭС, скрытые один слой увеличения разрешения и два сверточных слоя декодировщика, а также выходной сверточный слой. После прохождения всех слоев на выходе получается двумерный массив того же размера, что и входной имидж УЭС.




Рис. 2. Архитектура ИНС (сверточный автокодировщик) для подавления случайных помех на изображениях УЭС

Из-за потерь при кодировании сигналы БКС восстанавливаются с ошибками, для минимизации которых в процессе обучения подбираются такие сверточные фильтры, чтобы отбирать наиболее важные признаки, исключая случайные помехи. Обучение ИНС осуществляется алгоритмом Adam, основанном на адаптивной оценке момента [Kingma, Ba, 2015], а минимизируемая при обучении функция потерь выглядит следующим образом:

$$L(x, \hat{x}) = MSE(x, f(g(\hat{x}))),$$

где MSE – среднеквадратичное отклонение, x – незашумленный снимок УЭС, f – декодировщик, g – кодировщик, \hat{x} – зашумленный снимок УЭС.

После получения оптимальных значений параметров сверточных фильтров ИНС может использоваться для подавления случайных помех на изображениях УЭС. Тестирование алгоритма проводится на синтетических данных из отложенного набора, которые не были задействованы при обучении (рис. 3).




Рис. 3. Исходные изображения УЭС по результатам трехмерного численного моделирования с добавлением случайных помех, не задействованные при обучении (слева), и результат их обработки сверточным автокодировщиком (справа)

В таблице 1 приводятся результаты оценки качества работы разработанного алгоритма на обучающих и тестовых данных. Качество работы оценивается на основе индекса структурного сходства SSIM (от англ. structure similarity) истинных и восстанавливаемых имиджей УЭС, который несет в себе информацию о структуре объектов, представленных на изображениях [Wang et al., 2004], и рассчитывается по формуле

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)},$$

где x – незашумленный имидж УЭС; y – результат работы ИНС; μ_x, μ_y – средние значения x и y ; σ_x, σ_y – стандартные отклонения x и y ; σ_{xy} – ковариация x и y ; c_1, c_2 – переменные, зависящие от динамического диапазона x и y .

Для отложенных данных, не задействованных при обучении ИНС, SSIM составляет 0.946, что говорит о высоком качестве работы алгоритма.

Таблица 1

Результаты оценки качества работы алгоритма подавления случайных помех на имиджах УЭС на основе сверточного автокодировщика

Функция потерь / метрика	Результат (обучающие данные)	Результат (тестовые данные)
Функция потерь (среднеквадратичное отклонение)	0.004	0.005
Индекс структурного сходства	0.947	0.946

Анализ результатов работы алгоритма показывает, что в восстановленных имиджах УЭС сохраняется важная информация о пространственной ориентации границ вскрытых скважиной геоэлектрических слоев, при этом подавляются случайные помехи, что приводит к повышению достоверности результатов интерпретации. Из недостатков подхода можно отметить, что для получения на выходе адекватного исходным данным имиджа УЭС необходимо, чтобы в данных не было пропущенных точек измерения. Поскольку при каротаже в процессе бурения такая ситуация является типичной, перед применением разработанного алгоритма требуется предобработка данных с заполнением пропущенных точек измерения.

ДЕТЕКТИРОВАНИЕ ГРАНИЦ ПЛАСТОВ НА ИМИДЖАХ УЭС С ПРИМЕНЕНИЕМ ПОЛНОСВЕРТОВОЙ ИНС

Ключевым этапом интерпретации данных БКС в процессе бурения является детектирование границ пластов на имиджах УЭС, причем до сих пор нерешенной задачей является разработка

автоматического алгоритма детектирования границ, позволяющего восстанавливать их истинную пространственную ориентацию и характеризующегося низкой ресурсоемкостью. Как и в случае с подавлением случайных помех, перспективным направлением для решения данной задачи является комбинация трехмерного численного моделирования и современных методов машинного обучения, поскольку в качестве «ответов» ИНС может получать истинную разметку границ пластов, построенную по параметрам геоэлектрических моделей, в которых рассчитываются синтетические сигналы БКС. Важным этапом в разработке такого алгоритма становится переход от синтетическим данным к реальным измерениям, подверженным влиянию многих неучитываемых факторов, таких как неровности стенки скважины, текстурные особенности горных пород и другое.

При помощи ИНС решается задача поточечной бинарной классификации измерений на имиджах УЭС. На вход ИНС подается имидж УЭС произвольной длины, который затем проходит через ряд слоев, состоящих из сверточных фильтров, а на выходе преобразуется в массив того же размера, где каждой точке соответствует бинарное значение («граница» или «не граница»). При этом в качестве «ответов» используется разметка границ, построенная по истинным параметрам геоэлектрической модели, в которой рассчитываются синтетические сигналы прибора.

Архитектура разработанной ИНС (рис. 4) является полносверточной и включает в себя входной, три скрытых сверточных, а также выходной слои. В последнем слое происходит свертка с одним фильтром с последующей активацией в выходном слое при помощи сигмоидной функции, которая преобразует полученные значения в диапазон от 0 до 1. Таким образом, на выходе получается массив того же размера, что и исходный имидж УЭС, значения в котором соответствуют вероятности наличия границы в каждой конкретной точке. Задав пороговым значением вероятности равным 0.5, получаем итоговое предсказание наличия границ пластов на развертке стенки скважины.




Рис. 4. Архитектура ИНС (полносверточная нейросеть) для детектирования границ пластов на имиджах УЭС

В ходе обучения ИНС подбираются оптимальные параметры сверточных фильтров таким образом, чтобы вероятность наличия границы между пластами восстанавливалась наиболее близко к значению, указанному в разметке, построенной по параметрам геоэлектрической модели. Как и в задаче подавления случайных помех, обучение ИНС осуществляется алгоритмом Adam, а в качестве функции потерь используется логистическая функция перекрестной энтропии, которая штрафует ИНС как за высокую предсказанную вероятность там, где нет границы, так и за низкую предсказанную вероятность там, где граница есть:

$$L(y, p) = -y \lg(p) + (1 - y) \lg(1 - p),$$

где y – бинарное значение в разметке, которое подается в качестве «ответа», p – предсказываемое значение вероятности наличия границы пластов.

После получения оптимальных значений параметров модели в результате обучения, ИНС может использоваться для детектирования границ пластов на изображениях УЭС. Тестирование алгоритма, как и в прошлой задаче, проводится на синтетических данных из отложенного набора, которые не были задействованы непосредственно при обучении (рис. 5).




Рис. 5. Синтетические изображения УЭС из отложенного набора, незадействованные при обучении, с детектированными на них границами при помощи полносверточной ИНС

В таблице 2 приводятся результаты оценки качества классификации на основе ряда метрик:

$$\text{Доля верных ответов} = \frac{ИП + ИО}{ИП + ИО + ЛП + ЛО},$$

$$\text{Точность} = \frac{ИП}{ИП + ЛП},$$

$$\text{Полнота} = \frac{ИП}{ИП + ЛО},$$

$$F1 = \frac{\text{Точность} \cdot \text{Полнота}}{\text{Точность} + \text{Полнота}},$$

где $ИП$ – истинноположительное решение, $ИО$ – истинноотрицательное решение, $ЛП$ – ложноположительное решение, $ЛО$ – ложноотрицательное решение.

Следует отметить, что высокое значение доли верных ответов еще не говорит о высоком качестве работы алгоритма, поскольку данная метрика не чувствительна к несбалансированности классов в обучающей выборке (точек, соответствующих границам пластов, на имиджах гораздо меньше, чем точек, соответствующих отсутствию границ). В частности, полное отсутствие границ пластов в предсказании также характеризуется высокой долей верных ответов. Наиболее представительной из рассматриваемых метрик является F1-мера, объединяющая в себе информацию как о точности, так и о полноте алгоритма [Sasaki, 2007]. В результате тестирования на имиджах УЭС из отложенного набора получено значение F-меры более 0.83, что говорит о высоком качестве классификатора, т. е. разработанная ИНС, по большей части, предсказывает как наличие границы пластов в случае, когда граница на самом деле есть, так и отсутствие границы в случае, когда ее нет.

Таблица 2

Результаты оценки качества работы алгоритма детектирования границ пластов на имиджах УЭС на основе полносверточной ИНС

Функция потерь / метрика	Результат (обучающие данные)	Результат (тестовые данные)
Функция потерь (перекрестная энтропия)	0.083	0.097
Доля верных ответов	0.966	0.962
Точность	0.896	0.868
Полнота	0.844	0.802
F1-мера	0.690	0.662

Разработанный алгоритм обладает рядом преимуществ. Несмотря на относительно длительный процесс обучения ИНС, само ее применение для обработки имиджей УЭС занимает доли секунды в расчете на скважину, при этом возможна обработка имиджей УЭС произвольной длины, благодаря отсутствию в архитектуре ИНС полносвязных слоев. Кроме того, в отличие от известных методов детектирования границ пластов на имиджах УЭС, алгоритм ориентирован на определение истинного положения границ, поскольку ИНС обучается на разметке, построенной по заранее известным параметрам геоэлектрических моделей и тем самым неявно учитывает радиальную глубинность исследования прибора.

ВЫВОДЫ

С использованием оригинального подхода, позволяющего значительно сократить время выполнения ресурсоемких вычислений, создан набор данных для обучения ИНС, учитывающий истинные значения параметров пространственной ориентации границ геоэлектрических слоев. Полученный таким образом набор данных в дальнейшем может быть адаптирован под конкретную задачу.

Разработан и программно реализован алгоритм подавления случайных помех на имиджах УЭС на основе сверточной ИНС с архитектурой автокодировщика. В восстанавливаемых алгоритмом имиджах УЭС сохраняется важная информация о пространственной ориентации границ вскрытых скважиной пластов, при этом подавляются случайные помехи.

Разработан и программно реализован алгоритм детектирования границ пластов на имиджах УЭС на основе полносверточной ИНС. Поскольку ИНС обучается на разметке, построенной по заранее известным параметрам геоэлектрических моделей, алгоритм позволяет определять истинное положение границ пластов, неявно учитывая радиальную глубинность исследования прибора.

Разработанные алгоритмы позволяют оперативно (доли секунды в расчете на скважину) обрабатывать большие объемы данных, при этом, благодаря отсутствию в архитектуре ИНС полносвязных слоев, возможна обработка имиджей УЭС произвольной длины.

Исследование выполнено при финансовой поддержке проекта ФНИ № 0331-2019-0014 «Скважинная геофизика в электропроводящих анизотропных диспергирующих средах на основе высокопроизводительных решений трехмерных задач, высокоточных данных каротажа и лабораторных исследований керна».

ЛИТЕРАТУРА

Глинских В.Н., Никитенко М.Н., Даниловский К.Н., Еремин В.Н., Москаев И.А. Телеметрические системы каротажа: программно-методическое обеспечение в процессе бурения наклонно-горизонтальных скважин // *Neftegaz.RU*. – 2017. – Вып. 10. – С. 42–49.

Глинских В.Н., Даниловский К.Н., Нечаев О.В. Трехмерное численное моделирование сигналов азимутального микробоккового каротажа в процессе бурения // *Геология, геофизика и разработка нефтяных и газовых месторождений*. – 2018. – № 10. – С. 32–39.

Даниловский К.Н., Дудаев А.Р., Глинских В.Н., Никитенко М.Н., Москаев И.А. Программное обеспечение на основе web-технологий для геонавигации нефтегазовых скважин // *Вестник НГУ. Серия: Информационные технологии*. – 2019. – Т. 17, № 2. – С. 5–17.

Каюров К.Н., Еремин В.Н., Эпов М.И., Глинских В.Н., Сухорукова К.В., Никитенко М.Н. Аппаратура и интерпретационная база электромагнитного каротажа в процессе бурения // *Нефтяное хозяйство*. – 2014. – № 12. – С. 112–115.

Логинов Г.Н., Петров А.М. Автоматическое выделение геоэлектрических границ по данным бокового каротажного зондирования с помощью глубокой сверточной нейронной сети // *Геология и геофизика*. – 2019. – Т. 60, № 11. – С. 1650–1657, doi: 10.15372/GiG2019134.

Danilovskiy K., Glinskikh V., Nechaev O. 3D modelling of the new resistivity microimaging tool signals for logging while drilling // *The 80th EAGE Conference and Exhibition (Copenhagen, Denmark, June 11–14, 2018): Extended abstracts*. – Copenhagen, 2018. – Tu SP2 01, doi: 10.3997/2214-4609.201801679.

Danilovskiy K., Loginov G., Nechaev O. Automatic geoelectric boundaries detection on the resistivity images based on 3D numerical simulation and convolutional neural network // *The 9th Saint Petersburg International Conference and Exhibition (Saint Petersburg, Russia, November 16–19, 2020): Extended abstracts*. – St. Petersburg, 2020. – Paper 15, doi: 10.3997/2214-4609.202053015.

Danilovskiy K.N., Petrov A.M., Leonenko A.R., Sukhorukova K.V. Capabilities of convolutional neural networks based algorithms for solving resistivity logging tasks // *Data Science in Oil and Gas 2021 (Novosibirsk,*

Russia, 4–6 August 2021): Extended abstracts. – Novosibirsk, 2021. – Paper 39, doi: 10.3997/2214-4609.202156039.

Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, Cambridge, 2016. – Vol. 1. – 774 p.

Kingma D.P., Ba J. Adam: A method for stochastic optimization // 3rd International conference for learning representations (California, USA, May 7–9, 2015): Transactions. – San Diego, 2015. – Document ID: arxiv.org/abs/1412.6980.

Krizhevsky A., Sutskever I., Hilton G.E. Imagenet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems. – 2012. – Vol. 25. – P. 1097–1105.

Larsen D., Antonov Y., Luxey P., Skillings J., Skaug M., Wagner V. Navigating the horizontal section in a heterogeneous formation while using Extra Deep Azimuthal Resistivity for optimizing the wellbore placement within a narrow TVD window // SPWLA 57th Annual Logging Symposium (Reykjavik, Iceland, June 25–29, 2016): Transactions. – Reykjavik, 2016. – SPWLA-2016-Paper IIII.

Perlin K. An image synthesizer // SIGGRAPH Computer Graphics – 1985. – Vol. 19 (3). – P. 287–296, doi: 10.1145/325165.325247.

Sasaki Y. The truth of the F-measure // Teach. Tutor. Mater. – 2007. – Vol. 1 (5). – P. 1–5.

Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image quality assessment: from error visibility to structural similarity // IEEE Transactions on Image Processing. – 2004. – Vol. 13 (4). – P. 600–612, doi: 10.1109/TIP.2003.819861.

REFERENCES

Danilovskiy K., Glinskikh V., Nechaev O. 3D modelling of the new resistivity microimaging tool signals for logging while drilling // The 80th EAGE Conference and Exhibition (Copenhagen, Denmark, June 11–14, 2018): Extended abstracts. – Copenhagen, 2018. – Tu SP2 01, doi: 10.3997/2214-4609.201801679.

Danilovskiy K.N., Dudaev A.R., Glinskikh V.N., Nikitenko M.N., Moskaev I.A. Web-technologies based software for oil and gas wells geosteering // Vestnik NSU. Series: Information Technologies. – 2019. – Vol. 17 (2). – P. 5–17.

Danilovskiy K., Loginov G., Nechaev O. Automatic geoelectric boundaries detection on the resistivity images based on 3D numerical simulation and convolutional neural network // The 9th Saint Petersburg International Conference and Exhibition (Saint Petersburg, Russia, November 16–19, 2020): Extended abstracts. – St. Petersburg, 2020. – Paper 15, doi: 10.3997/2214-4609.202053015.

Danilovskiy K.N., Petrov A.M., Leonenko A.R., Sukhorukova K.V. Capabilities of convolutional neural networks based algorithms for solving resistivity logging tasks // Data Science in Oil and Gas 2021 (Novosibirsk, Russia, 4–6 August 2021): Extended abstracts. – Novosibirsk, 2021. – Paper 39, doi: 10.3997/2214-4609.202156039.

Glinskikh V.N., Nikitenko M.N., Danilovskiy K.N., Eremin V.N., Moskaev I.A. Telemetry logging systems: software and methodological support in the process of drilling inclined-horizontal wells // Neftegaz.RU. – 2017. – No. 10. – P. 42–49.

Glinskikh V.N., Danilovsky K.N., Nechaev O.V. 3D numerical simulation of the azimuthal microlateral LWD signals // Geology, Geophysics and Development of Oil and Gas Fields. – 2018. – No. 10. – P. 32–39.

Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, Cambridge, 2016. – Vol. 1. – 774 p.

Kayurov K.N., Eremin V.N., Epov M.I., Glinskikh V.N., Sukhorukova K.V., Nikitenko M.N. Electromagnetic-logging-while-drilling equipment and numerical inversion software // Oil industry. – 2014. – No. 12. – P. 112–115.

Kingma D.P., Ba J. Adam: A method for stochastic optimization // 3rd International conference for learning representations (California, USA, May 7–9, 2015): Transactions. – San Diego, 2015. – Document ID: arxiv.org/abs/1412.6980.

Krizhevsky A., Sutskever I., Hilton G.E. Imagenet classification with deep convolutional neural networks // Advances in Neural Information Processing Systems. – 2012. – Vol. 25. – P. 1097–1105.

Larsen D., Antonov Y., Luxey P., Skillings J., Skaug M., Wagner V. Navigating the horizontal section in a heterogeneous formation while using Extra Deep Azimuthal Resistivity for optimizing the wellbore placement within a narrow TVD window // SPWLA 57th Annual Logging Symposium (Reykjavik, Iceland, June 25–29, 2016): Transactions. – Reykjavik, 2016. – SPWLA-2016-Paper IIII.

Loginov G.N., Petrov A.M. Automatic detection of geoelectric boundaries according to lateral logging sounding data by applying a deep convolutional neural network // Russ. Geol. Geophys. – 2019. – Vol. 60 (11). – P. 1319–1325, doi: 10.15372/RGG2019134.

Perlin K. An image synthesizer // SIGGRAPH Computer Graphics – 1985. – Vol. 19 (3). – P. 287–296, doi: 10.1145/325165.325247.

Sasaki Y. The truth of the F-measure // Teach. Tutor. Mater. – 2007. – Vol. 1 (5). – P. 1–5.

Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image quality assessment: from error visibility to structural similarity // IEEE Transactions on Image Processing. – 2004. – Vol. 13 (4). – P. 600–612, doi: 10.1109/TIP.2003.819861.

КОРОТКО ОБ АВТОРАХ

ДАНИЛОВСКИЙ Кирилл Николаевич – научный сотрудник лаборатории многомасштабной геофизики Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: геофизические методы исследований в скважинах, каротаж в процессе бурения, обработка и интерпретация данных ГИС, моделирование и инверсия данных электрокаротажа, машинное обучение, искусственные нейронные сети.

ЛОГИНОВ Георгий Николаевич – научный сотрудник лаборатории динамических проблем сейсмологии Института нефтегазовой геологии и геофизики СО РАН. Основные научные интересы: обработка сейсмических данных и методы машинного обучения в геофизике.

*Статья поступила в редакцию 13 августа 2021 г.,
принята к публикации 6 сентября 2021 г.*