

АВТОМАТИЧЕСКОЕ ВЫДЕЛЕНИЕ ГЕОЭЛЕКТРИЧЕСКИХ ГРАНИЦ ПО ДАННЫМ БОКОВОГО КАРОТАЖНОГО ЗОНДИРОВАНИЯ С ПОМОЩЬЮ ГЛУБОКОЙ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Г.Н. Логинов, А.М. Петров

*Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,
630090, Новосибирск, просп. Академика Коптюга, 3, Россия*

Боковое каротажное зондирование (БКЗ) — единственный на сегодняшний день широко применяемый российский метод электротометрии, чувствительный к вертикальному удельному электрическому сопротивлению (УЭС) в вертикальных скважинах. Однако интерпретация данных этого метода, измеренных в тонкослоистых разрезах, сложна и требует привлечения ресурсоемких алгоритмов численного моделирования. Развитие вычислительных методов и увеличение производительности компьютеров позволяют сегодня проводить инверсию данных БКЗ в классе двумерных осесимметричных моделей. Из-за большого количества сложностей, связанных с нелокальностью отклика приборов и их асимметрией, этот процесс требует активного участия интерпретатора. Одной из первых проблем является создание начального приближения геоэлектрической модели — разбиение целевого интервала на пласты, в пределах которых свойства среды можно считать неизменными по вертикали, так как сигналы БКЗ имеют очень сложный вид на интервалах переслаивания различных по УЭС пород. В работе предлагается использование полносвязной сверточной искусственной нейронной сети для автоматического создания пластовой разбивки, пригодной для построения начального приближения геоэлектрической модели для двумерной инверсии данных БКЗ, в том числе с определением вертикального УЭС. Нейронная сеть обучена и протестирована на синтетических и практических данных, измеренных в Западной Сибири. По результатам тестирования установлена работоспособность предлагаемого подхода.

Боковое каротажное зондирование, выделение границ, двумерная инверсия, машинное обучение, искусственные нейронные сети, сверточные нейронные сети.

AUTOMATIC DETECTION OF GEOELECTRIC BOUNDARIES ACCORDING TO LATERAL LOGGING SOUNDING DATA BY APPLYING A DEEP CONVOLUTIONAL NEURAL NETWORK

G.N. Loginov and A.M. Petrov

Lateral logging sounding (LLS) is currently the only widely used Russian method of resistivity measurements, sensitive to vertical electrical resistivity in vertical wells. However, interpreting data measured by this method in thin-layered sections is difficult and requires the utilization of resource-intensive numerical simulation algorithms. Today, the development of computational methods and an increase in computer performance allow us to invert LLS data in the class of two-dimensional axisymmetric models. However, in virtue of the large number of difficulties associated with the nonlocal responses of the probes and their asymmetry, this process requires the active participation of a log analyst. One of the first issues is the creation of an initial approximation of the geoelectric model. It consists in splitting the target interval into layers within which the properties of the medium can be considered constant in the vertical direction, since LLS signals have a very complex shape in the intervals of alternation of beds with different resistivities. We propose applying a fully connected convolutional artificial neural network to automatically create sectional layering suitable for constructing the initial approximation of the geoelectric model for two-dimensional LLS data inversion, including vertical resistivity estimation. The neural network was trained and tested on the synthetic and field data measured in West Siberia. Based on the results of the testing, we established the workability of the proposed approach.

Lateral logging sounding, boundary detection, two-dimensional inversion, machine learning, artificial neural networks, convolutional neural networks

ВВЕДЕНИЕ

В настоящее время из-за сложности интерпретации в тонкослоистом разрезе метод бокового каротажного зондирования (БКЗ) все реже используется для количественной оценки удельного электрического сопротивления (УЭС) пластов-коллекторов. Однако увеличение вычислительных ресурсов современных компьютеров и развитие эффективных алгоритмов численного моделирования сигналов

каротажа позволяют проводить инверсию данных БКЗ в классе двумерных осесимметричных моделей. Такой подход естественным образом учитывает влияние границ на форму сигналов и позволяет оценивать параметры пластов малой мощности, что практически невозможно при использовании палеток. Более того, при двумерной инверсии данных БКЗ становится возможной оценка вертикального УЭС. Это обусловлено тем, что сигналы существенно зависят от электрической анизотропии пласта вблизи его границ или даже ниже его подошвы [Сухорукова и др., 2017]. БКЗ является единственным широко применяемым в России методом электрометрии, чувствительным к вертикальному УЭС и сейчас может быть вполне адекватной альтернативой существенно более сложным трехкомпонентным приборам индукционного каротажа. Этот метод уже с начала 50-х годов прошлого века был включен в обязательный отечественный комплекс каротажа в нефтегазовых скважинах. Поэтому в настоящее время для обработки и переинтерпретации доступен большой массив архивных материалов. Таким образом, результаты интерпретации данных БКЗ являются источником независимой достоверной информации об электрической анизотропии горных пород при построении детальных геоэлектрических моделей.

Несмотря на успехи в экспресс-моделировании сигналов, в настоящее время процесс двумерной инверсии данных БКЗ требует активного участия специалиста-интерпретатора. Автоматизация инверсии связана с большим числом методических и алгоритмических проблем, первой из которых является создание начального приближения геоэлектрической модели. Алгоритмы численного моделирования используют в основном кусочно-постоянное разбиение среды, поэтому для ее создания необходимо разделить целевой интервал на пласты, в пределах которых УЭС можно считать неизменным по вертикали.

Расстановка горизонтальных границ в геологическом разрезе с целью выделения однородных по свойствам интервалов — классическая подзадача интерпретации данных ГИС. На сегодняшний день есть широкий набор алгоритмов автоматического выделения пластов по данным различных методов или комплексов методов, например, [Maiti, Tiwari, 2005; Бердов и др., 2012]. Большая их часть основана на градиентном или дисперсионном подходе. Однако они неприменимы для БКЗ, поскольку все зонды являются несимметричными. Для диаграмм БКЗ характерна сложная асимметричная форма, зависящая как от толщины пласта, контраста УЭС пласта и вмещающих пород, так и от параметров скважины. Переход градиент-зондов через границу отмечается экстремумами на диаграммах кажущихся сопротивлений (КС). Это существенно упрощает их выделение. На разрезах с переслаиванием дифференцированных по УЭС пород на диаграммах возникает большое число экстремумов, не связанных с пересечением границы. Это не позволяет их напрямую использовать в качестве индикаторов границ. Дискретность отсчетов по глубине и измерений смещает положения экстремумов и уменьшает их значения. Влияние вертикального УЭС также изменяет форму диаграмм при подходе к анизотропным пластам. Таким образом, с одной стороны, для метода БКЗ трудно сформулировать надежный формальный критерий выделения границы, а с другой, пропуск тонкого, но электрически контрастного слоя — характерная ошибка градиентного и дисперсионного методов — может критически сказаться на результатах инверсии.

В настоящее время искусственные нейронные сети и машинное обучение широко используются при обработке и интерпретации геофизических данных. Например, для совместной корреляции данных каротажа и сейсморазведки [Naris et al., 2018], выделения геологических объектов на сейсмических изображениях [Zhang et al., 2018] и ускорения прямых и обратных задач БКЗ [Агбаш, Соболев, 2016].

В работе для задачи детектирования границ по данным БКЗ использована полносвязная сверточная нейронная сеть.

АРХИТЕКТУРА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Выбор архитектуры нейронной сети определяется следующими ключевыми факторами: тип решаемой задачи (регрессия, классификация, прогнозирование); тип и размер входных данных (цифровые сигналы, изображения и т.д.); функциональные ограничения (точность, скорость работы). Задача детектирования границ сводится к бинарной классификации каждого измерения БКЗ по глубине на два класса: граница и не граница (True/False). Следует отметить, что в общем случае положения границ не совпадают с положением точек измерений, т. е. при использовании такого подхода положение границ определяется с точностью лишь до половины шага дискретизации. Тем не менее этой точности достаточно для создания стартовой модели для двумерной инверсии, так как современные алгоритмы уточняют положения границ в процессе подбора сигналов.

Тип решаемой задачи главным образом влияет на вид оптимизируемой целевой функции. Входными данными являются показания нескольких зондов (обычно не более 6). В работе используются сигналы только градиент-зондов, поскольку конструкция потенциал-зонда приводит к другой форме сигналов при пересечении границ и к низкой разрешающей способности. Это может негативно сказаться на работе алгоритма. В процессе инверсии могут анализироваться интервалы записи вдоль ствола скважины разной длины. Следовательно, с точки зрения функциональных ограничений следует отме-

тить необходимость организации архитектуры сети без привязки к конкретной длине записи. Таким образом, с учетом типа данных наиболее рационально использовать свертку в качестве ядра операторов обучения.

Базовыми элементами архитектуры искусственной нейронной сети являются слои и нейроны. Число слоев и нейронов в большинстве случаев отвечает за регуляризацию решения задачи и устанавливается экспериментально. Отдельный слой сети состоит из нейронов, каждый из которых отвечает за выделение некоторого «абстрактного» признака [Goodfellow et al., 2016]. Под обучением сверточной нейронной сети подразумевается вычисление фильтров для входных данных, наилучшим образом выделяющих особенности, требуемые для решения задачи классификации. Процесс обучения — это минимизация функционала невязки L между исходной разметкой данных y и результатами работы нейронной сети p :

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

где $p \in [0, 1]$ — вероятность принадлежности к классу True (наличие границы), а $y = 0$ или 0.1.

В настоящее время проведено множество исследований о применении различных архитектур нейронных сетей в задачах компьютерного зрения. Мы применили полносвязную сверточную нейронную сеть (ПНС) различных конфигураций. Результаты их применения сравниваются при помощи ROC-кривой (Receiver Operating Characteristic) и сводной таблицы точности. Архитектура ПНС подразумевает, что каждый нейрон каждого слоя связан со всеми нейронами на следующем и предыдущем слоях.

Обучение нейронной сети осуществлялось методом Adam (adaptive moment estimation — адаптивная оценка момента) [Kingma, Ba, 2014], который практически не требует сложной настройки и широко используется при обучении нейронных сетей.

ОБУЧАЮЩАЯ ВЫБОРКА И ПРОЦЕСС ОБУЧЕНИЯ

Для решения задачи автоматизации выделения границ с помощью сверточной нейронной сети необходимы модели, содержащие горизонтальные границы между слоями всех типов радиального строения. В более ранних работах оценена эквивалентность сигналов от различных моделей и выявлено, что аппроксимация радиального изменения УЭС кусочно-постоянным профилем практически не влияет на форму сигналов при пересечении границ даже при грубом разбиении зон пласта на зону проникновения (ЗП), окаймляющую зону (ОЗ) и неизменную часть [Петров и др., 2017]. Другим важным параметром является толщина слоев: градиент-зонды являются несфокусированными, и на показания длинных зондов сильно влияют вмещающие породы. Задача выделения горизонтальных границ тем сложнее, чем меньше характерная толщина слоев, поэтому при моделировании сигналов для обучающей выборки использовались небольшие толщины. Дополнительно осложняет ситуацию широко известное влияние анизотропии УЭС на форму сигналов БКЗ при пересечении границ [Fitch, 1982].

Обучение искусственной нейронной сети проводилось на синтетических сигналах БКЗ комплекса СКЛ-76 [Каюров и др., 2015] и практических сигналах комплексов СКЛ-76 и К1А-723 (НПФ «Геофизика», Уфа). Все данные были представлены с шагом дискретизации измерений по глубине 0.2 м. Обучение проводилось в два этапа. На первом этапе использовались синтетические сигналы БКЗ комплекса СКЛ-76, рассчитанные с помощью конечно-элементного алгоритма комплекса AlondraWL [Сухорукова и др., 2017] с учетом влияния скважины и вытеснения прибором проводящего раствора. Пять случайно сгенерированных моделей среды содержали по 500 слоев (суммарная толщина от 400 до 650 м), соот-

Таблица 1. Параметры синтетических моделей терригенных отложений Западной Сибири

№ п/п	Литотип	ЗП		ОЗ		Пласт УЭС, Ом·м
		УЭС, Ом·м	h , м	УЭС, Ом·м	h , м	
1	Песчаник нефтенасыщенный	15—30	0.2—0.7	—	—	16—30
2	Песчаник нефтеводонасыщенный	15—30	0.2—0.6	3—6	0.1—0.25	7—20
3	Песчаник водонасыщенный	12—20	0.2—0.7	—	—	3—8
4	Песчаник карбонатизированный	—	—	—	—	$\rho_h = 20 - 500/\lambda = 1 - 1.2$
5	Глинистые отложения	—	—	—	—	$\rho_h = 3 - 8/\lambda = 1 - 3.5$
6	Анизотропный песчано-глинистый коллектор	*	*	*	*	*

* Параметры анизотропных песчано-глинистых коллекторов определялись по формулам для переслаивания песчаных (1—3) и глинистых (5) отложений [Hagiwara, 2013].

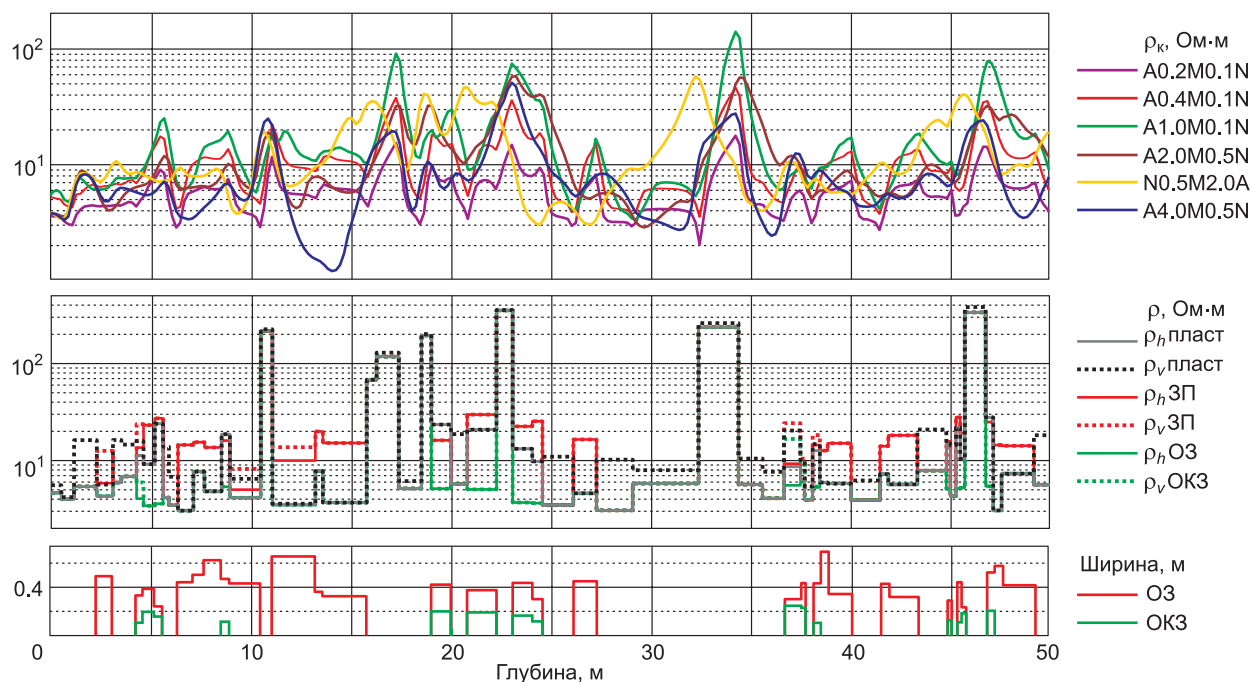


Рис. 1. Фрагмент модели терригенных отложений и сигналы БКЗ, рассчитанные в ней.

ветствующих по УЭС терригенным отложениям Западной Сибири (табл. 1). Параметры слоев внутри литотипов распределены равномерно. Толщина слоев распределена логнормально со сдвигом на 0.15 м. Выделение пропластков толщиной менее шага дискретизации не представляется возможным, однако при практических измерениях они могут присутствовать в разрезе. Поэтому для того, чтобы сделать выборку более приближенной к регистрируемым на практике данным, в синтетические модели добавлены прослой толщиной менее шага дискретизации. Добавление таких тонких слоев можно рассматривать как дополнительное зашумление данных.

Модели различаются распределением толщин слоев, соотношением числа слоев различных литотипов и УЭС бурового раствора. Разделение на литотипы условное: дифференциация отложений по данным БКЗ возможна лишь по величине УЭС и типу его радиального изменения. Поэтому используемые модели следует рассматривать как геоэлектрические: они хорошо описывают большинство вероятных форм сигналов вблизи границ между разными терригенными породами, но не являются литологическим описанием разреза. Фрагмент модели и пример синтетических сигналов приведен на рис. 1.

Для создания обучающей выборки отрезки кривых БКЗ и соответствующие им положения границ пластов формировались случайным образом из синтетических и практических данных. Пластовая разбивка практических измерений проводилась по данным комплекса скважинной электрметрии. Общее количество используемых практических данных составило 1 км (5000 отчетов по глубине). Формируемые из одной модели отрезки могли частично перекрываться. Обучающая выборка составила 4000 примеров записи сигналов БКЗ и соответствующих им границ, по 64 отчета каждая. Пример такого отрез-




Рис. 2. Пример отрезка практических диаграмм, измеренных в скважине Федоровского месторождения, использованных для обучения сети.

Таблица 2. Результаты экспериментов по выбору параметров нейронной сети

Количество фильтров/длина фильтра	3 слоя	4 слоя	5 слоев	6 слоев
16/16	89.4/66.4	87.9/60.9	87.9/67.9	89.4/66.1
16/32	88.9/60.9	91.9/64.2	85.4/60.2	90.0/65.3
32/16	87.0/60.4	83.1/59.2	77.3/51.2	75.7/51.4
32/32	87.2/61.4	80.8/58.9	77.9/53.8	75.1/56.5

Примечание. В столбцах указана площадь (усл. ед.) под кривой ROC и точность, %.

ка приведен на рис. 2. Число отсчетов в примерах для обучения выбрано экспериментально. На вход нейронной сети данные подавались в логарифмическом масштабе, дополнительной обработки или масштабирования не проводилось. В результате использования нейронной сети ко входным данным, каждой отметке глубины присваивается вероятность наличия границы. Сверточная модель нейронной сети, позволяет применять обученную модель к данным произвольной длины.

Для выбора оптимальных параметров нейронной сети проведена серия экспериментов, которые заключались в подборе оптимального числа слоев, длины и числа фильтров. В таблице 2 представлен сравнительный анализ качества работы обученных нейронных сетей на полном имеющемся наборе модельных и реальных данных, состоящем из 17 000 точек измерений по глубине. Для большинства методов машинного обучения и нейронных сетей, в частности, выбор метрик качества работы не очевиден, поэтому в таблице приведены три метрики, по которым можно оценить эффективность предложенного подхода: невязка, площадь под кривой ROC и минимальная точность по всем рассмотренным тестовым моделям разрезов. Под точностью понимается процент правильных ответов по отношению к общему числу примеров. Такой подход к анализу результатов был выбран с целью определения минимального порога работоспособности подхода для разных разрезов.

По результатам экспериментов выбрана нейронная сеть из четырех слоев с 16 фильтрами, где каждый длиной 32 отсчета. Необходимо отметить, что в случае модельных данных, точность в среднем составляла выше 90 %, тогда как на реальных данных могла составлять порядка 60 %. Данный результат, помимо прочего, связан с высокой степенью неоднозначности выделения границ на реальных данных. Так, метрика точности может значительно снизиться, если нейросеть детектирует границу в соседнем отсчете от указанного интерпретатором. Очевидно, что при практическом использовании алгоритма данный эффект не будет иметь значения.

Обученная нейронная сеть была применена к каждой модели скважины по отдельности. В качестве основного критерия успешности работы обученной нейронной сети использовалась площадь под графиком кривой ROC (Receiver Operating Characteristic, рабочая характеристика приемника) для разных моделей околоскважинного пространства (рис. 3). Кривая ROC демонстрирует чувствительность верных положительных (True, наличие границы) срабатываний алгоритма к ложным. Верным положительным срабатыванием называется случай, когда алгоритм верно указывает положение границы. Ложным положительным срабатыванием называется случай, когда алгоритм указывает наличие границы там, где ее нет. По вертикальной оси откладывается процент верных правильных ответов, по горизонтальной — процент ложных правильных ответов. Скорость верных положительных срабатываний — это отношение верно предсказанных положительных ответов к общему числу положительных значений (True — наличие границы). Скорость ложных положительных срабатываний — это отношение числа ложных положительных срабатываний к общему числу негативных значений (False — отсутствие границы).

Для синтетических данных (model_1 — model_5) площадь под кривой составляет не менее 90 %, что соответствует высокой точности работы алгоритма. Для реальных данных с Федоровского месторождения (F3_mezozoyu) площадь составляет 89 % от максимально возможной площади под кривой ROC, что также демонстрирует высокую надежность предлагаемого подхода.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Обученная нейронная сеть протестирована на модельных и реальных данных. На рисунке 4 представлены результаты тестирования алгоритма на практических данных, измеренных на Русскинском месторождении. Сопоставление выделенных границ с данными высокочастотного изопараметрического каротажного индукционного зондирования (ВИИКЗ) и бокового каротажа (БК) показывает работоспособность предложенного подхода.

Тем не менее на этом примере можно выделить пропущенную границу (показана штриховой линией) и неоднозначную работу на интервале с плавным изменением УЭС с глубиной (xx70 — xx72 м).




Рис. 3. ROC кривые применения сверточной полносвязной нейронной сети для разных синтетических моделей околоскважинного пространства (model_1 — model_5) и реальных данных. В легенде указана площадь под графиком ROC-кривой (area).

В таких условиях алгоритм аппроксимирует плавное изменение достаточно частым кусочно-постоянным разбиением. Такое поведение может быть как верным, так как большинство существующих алгоритмов инверсии БКЗ основаны на кусочно-постоянной параметризации среды, так и приводить к выделению слишком тонких прослоев там, где в этом нет необходимости.

В обучающей выборке акцент сделан на интервалы переслаивания достаточно тонких просло-

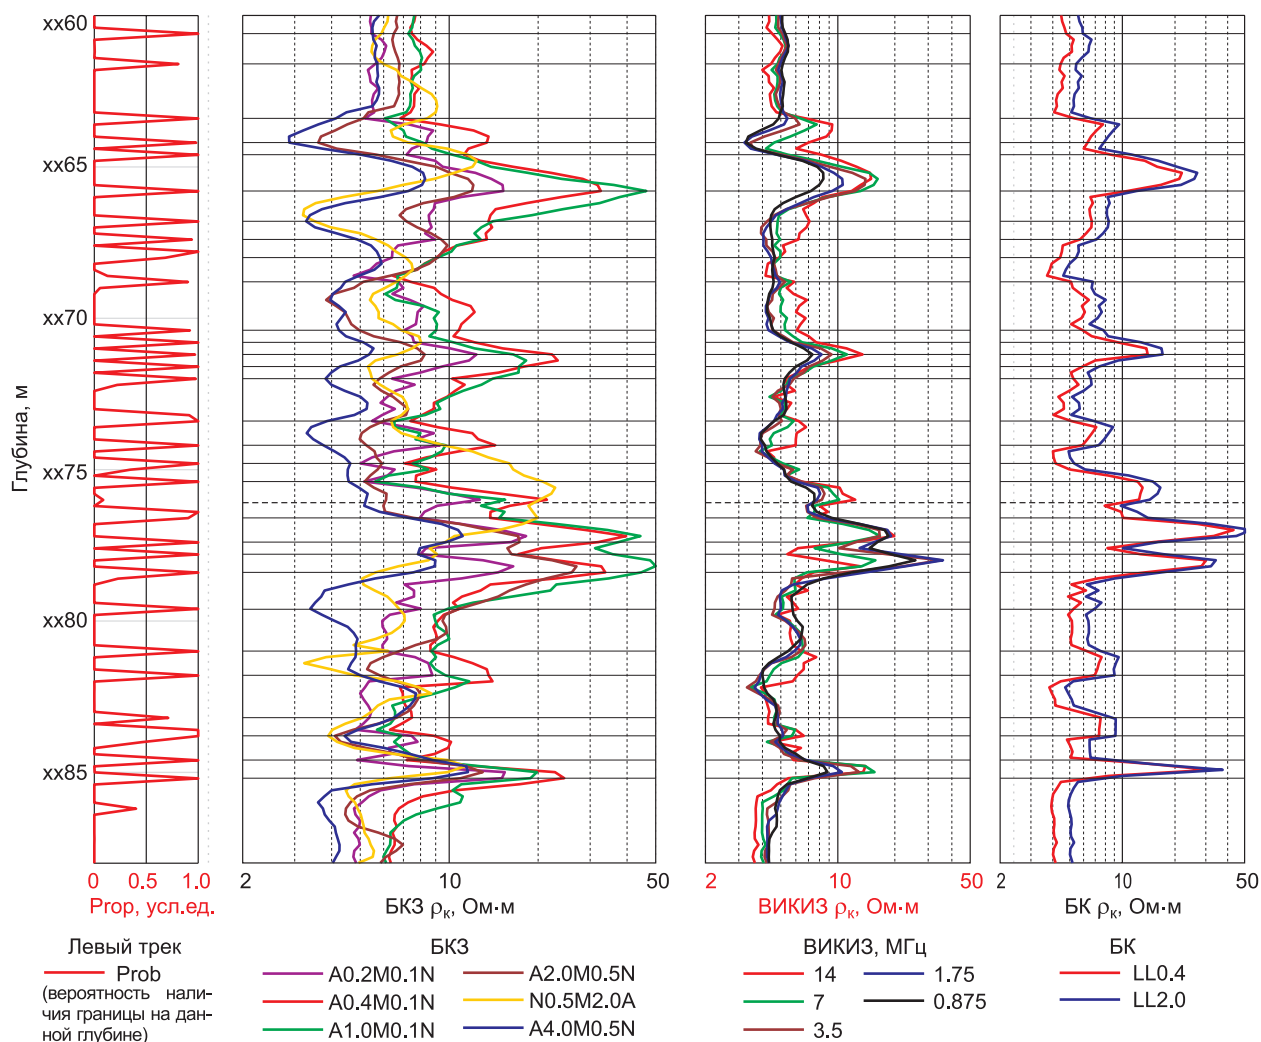


Рис. 4. Результат применения алгоритма к практическим данным, измеренным на Рускинском месторождении.

Сплошными серыми горизонтальными линиями показаны геоэлектрические границы, выделенные алгоритмом. Штриховая линия — граница, пропущенная алгоритмом.

ев, так как именно такие разрезы наиболее сложны для ручной расстановки границ, для корректного восстановления их параметров необходима двумерная инверсия. Для расширения условий применимости алгоритма и повышения его точности желательно увеличить представительность обучающей выборки примерами сигналов, измеренных в разных геологических условиях. Рассматриваемая архитектура нейронной сети не требует больших вычислительных ресурсов для обучения. Это позволяет выполнить обучение заново или провести дообучение для адаптации под конкретные геологические условия или месторождение.

Следует отметить, что применительно к практическим данным в разрезах, где изменение УЭС по вертикали может отличаться от кусочно-постоянного, само понятие границы не всегда применимо в полной мере. Результатом работы данного алгоритма является вероятность нахождения границы на каждой глубине, ее преобразование в пластовую разбивку производится с помощью порогового коэффициента. Поэтому вопрос о правильности расстановки границ в том или ином случае всегда будет зависеть от мнения конкретного интерпретатора. Но даже в самых сложных средах с тонким переслаиванием или градиентным изменением УЭС по глубине ручная работа сводится к исправлению относительно небольшого числа допущенных алгоритмом ошибок на основе анализа значений вероятности, что по сравнению с ручной расстановкой значительно ускоряет процесс и минимизирует ошибки в сложных разрезах.

ВЫВОДЫ

Разработан алгоритм автоматического детектирования геоэлектрических границ по данным БКЗ на основе полносвязной сверточной нейронной сети. Алгоритм обучен на типичных для терригенных отложений Западной Сибири синтетических и практических данных, в том числе, соответствующих измерениям на интервалах анизотропных отложений. Алгоритм способен выделять в разрезе как достаточно мощные пласты, так и тонкие, но контрастные по УЭС пропластки, поэтому его использование позволяет генерировать применимую для двумерной инверсии данных пластовую разбивку сложных разрезов с минимальным участием интерпретатора. Существенно, что расчет результатов работы нейронной сети не требует серьезных вычислительных ресурсов и времени. Помимо этого, для применения нейронной сети не требуется выполнять предварительную подготовку данных: алгоритм может работать с необработанными измерениями в формате .las.

Алгоритмическая часть исследования выполнена при финансовой поддержке РФФИ в рамках научного проекта № 18-35-00412. Методическая часть исследования и формирование обучающей выборки — при 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

Агбаш И.А., Соболев А.Ю. Построение быстрых аналогов прямых и обратных задач бокового электрического зондирования скважин с использованием технологии нейронных сетей // Интерэкспо ГЕО-Сибирь-2017. XI Междунар. науч. конгр. (18–22 апреля 2016 г., Новосибирск), сб. материалов в 4 т. Т. 2. Новосибирск, СГУГиТ, 2016, № 1, с. 196—200.

Бердов В.А., Власов А.А., Лапковский В.В. Выделение пластов межскважинного пространства по данным каротажа в программном комплексе Petrel // Интерэкспо ГЕО-Сибирь-2012. VIII Междунар. науч. конгр. (10–20 апреля 2012 г., Новосибирск), сб. материалов в 3 т. Т. 2. Новосибирск, СГГА, 2012, с. 76—80.

Каюров К.Н., Еремин В.Н., Петров А.Н., Сухорукова К.В., Никитенко М.Н., Аржанцев В.С. Аппаратурный комплекс СКЛ для каротажа в нефтегазовых скважинах и его интерпретационная база // Нефтяное хозяйство, 2015, № 9, с. 38—43.

Петров А.М., Сухорукова К.В., Нечаев О.В. Возможности и ограничения восстановления параметров анизотропных осесимметричных моделей среды путем инверсии данных БКЗ // Интерэкспо ГЕО-Сибирь-2017. XII Междунар. науч. конгр. (17–21 апреля 2017 г., Новосибирск), сб. материалов в 4 т. Т. 3. Новосибирск, СГУГиТ, 2017, с. 181—186.

Сухорукова К.В., Петров А.М., Нечаев О.В. Численная инверсия данных электрокаротажа в интервалах анизотропных глинистых отложений // НТВ «Каротажник», 2017, № 4 (274), с. 34—48.

Fitch A. A. Developments in geophysical exploration methods — 3. London, Elsevier, Applied Science Publishers, 1982, 310 p.

Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge, MIT press, 2016, v. 1, 774 p.

Hagiwara T. Macroscopic anisotropy at multiple scales // SPWLA 54th Annual Logging Symposium, 22—26 June, New Orleans, Louisiana, 2013.

Haris A., Murdianto B.S., Sutatto R., Riyanto A. Transforming seismic data into lateral sonic properties using artificial neural network: a case study of real data set // Int. J. Technol., 2018, т. 9, № 3, p. 472—478.

Kingma D.P., Ba J. Adam: A method for stochastic optimization // arXiv preprint arXiv, 15, 2014, 1412.6980. <https://arxiv.org/abs/1412.6980>.

Maiti S., Tiwari R.K. Automatic detection of lithologic boundaries using the Walsh transform: A case study from the KTB borehole // Comput. Geosci., 2005, 31(8), p. 949—955.

Zhang G., Wang Z., Chen Y. Deep learning for seismic lithology prediction // Geophys. J. Int., 2018, 215 (2), p. 1368—1387.

*Рекомендована к печати 22 мая 2019 г.
И.Н. Ельцовым*

*Поступила в редакцию 8 ноября 2018 г.,
после доработки — 2 марта 2019 г.*