

Работы молодых ученых

УДК 550.837.311

DOI: 10.31431/1816-5524-2024-2-62-109-119

ВОЗМОЖНОСТИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ПРИ РЕШЕНИИ ОБРАТНЫХ ЗАДАЧ ЭЛЕКТРОРАЗВЕДКИ МЕТОДОМ ВЕРТИКАЛЬНОГО ЭЛЕКТРИЧЕСКОГО ЗОНДИРОВАНИЯ

© 2024 Р.Н. Петросян, Н.В. Рыжов

*Пермский государственный национальный исследовательский университет,
Пермь, Россия, 614068; e-mail: petrosyan@antikarst.ru*

Поступила в редакцию 23.12.2023; после доработки 07.05.2024; принята в печать 25.06.2024

Представлен алгоритм решения обратной задачи электроразведки методом вертикального электрического зондирования (ВЭЗ) с помощью нейронных сетей (НС). Использование НС направлено на выявление сложных закономерностей и зависимостей, которые могут быть недоступны для традиционных методов количественной интерпретации данных электроразведки. Алгоритм включает в себя формирование обучающей выборки; обучение НС и непосредственно получение решений; комбинацию вариантов решений, найденных с помощью НС и выбор оптимального решения обратной задачи ВЭЗ. Алгоритм апробирован на модельных данных и практических материалах с целью оценки его возможностей. Геоэлектрические разрезы, построенные с применением НС по результатам полевых наблюдений, сравнивались с результатами количественной интерпретации, выполненной в программе «ЗОНД». Охарактеризованы преимущества и недостатки созданного алгоритма решения обратной задачи ВЭЗ, а также пути его дальнейшего развития.

Ключевые слова: электроразведка, вертикальное электрическое зондирование, обратная задача, нейронные сети.

ВВЕДЕНИЕ

Обратная задача (ОЗ) — тип задач, часто возникающий во многих разделах науки, когда значения параметров модели должны быть получены из наблюдаемых данных. Специфическими особенностями обратной задачи являются отсутствие единственности ее решения и неустойчивость получаемых результатов. Такие задачи в математической физике носят название «некорректных».

Вследствие этого, определение «наилучшего» решения, которое наиболее адекватно отражает реальную физико-геологическую ситуацию, остается непростой задачей. Существует большое количество подходов к решению ОЗ в прикладной геофизике, в том числе с помощью нейронных сетей (НС).

НС широко распространены в различных отраслях науки и техники уже в конце XX в. Они успешно применяются для решения отдельных задач в геологоразведочной отрасли, в особенности — в геофизических методах исследований скважин (ГИС): для интерпретации данных гамма каротажа и каротажа сопротивления и последующего выделения фаций (Родина, Силкин, 2007); идентификации путей фильтрации углеводородов в трехмерном пространстве на основе данных ГИС (Шайбаков, 2014). Изучались также особенности подготовки исходных данных к интерпретации результатов ГИС с использованием НС (Костиков, 2007).

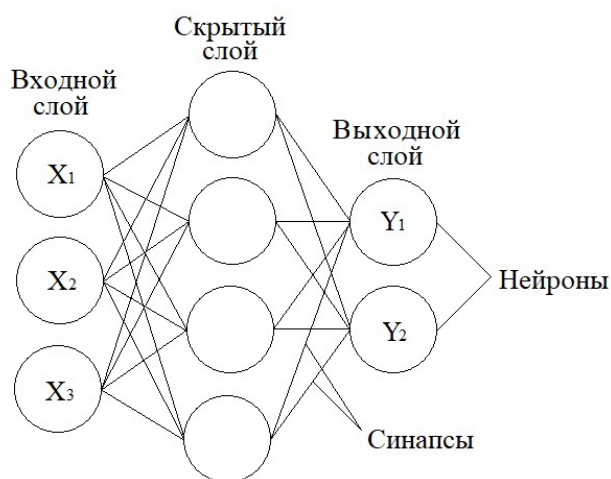
В электроразведке НС широко используются для решения различных задач: получение НС-палеток, предназначенных для инверсии магнитотеллурических данных (Оборнев, 2013); решение ОЗ

магнитотеллурического зондирования в классе блочных моделей сред (Шимелевич и др., 2018); определение в геоэлектрическом разрезе неоднородного слоя с частотной дисперсией электропроводности по данным магнитотеллурического зондирования (Московский и др., 2015). Проведены анализ и обобщение результатов ранних исследований на тему применения НС при решении нелинейных и многокритериальных ОЗ электроразведки (Оборнев и др., 2020), в том числе с использованием НС, основанных на сверточной архитектуре (Шимелевич., 2021).

В настоящей статье представлен опыт использования НС для решения ОЗ электроразведки методом вертикального электрического зондирования (ВЭЗ) при инженерно-геологических изысканиях с целью расчленения геологического разреза и определения уровня грунтовых вод. Авторами статьи на языке программирования «Python» был разработан алгоритм, который основывается на открытой библиотеке «Keras», реализованной Ф. Шолле (F. Chollet) для создания НС различной степени сложности (Keras..., 2023). Помимо библиотеки «Keras», использовалась открытая библиотека «руGIMLi», предназначенная, в частности, для решения прямой задачи ВЭЗ. Библиотека «руGIMLi» является продуктом сотрудничества специалистов в области геофизики из Германии: К. Рюкер; Т. Гюнтер; Ф.М. Вагнер (Rücker et al., 2017)

МЕТОДЫ ИССЛЕДОВАНИЙ

Для решения ОЗ ВЭЗ используется НС, представляющая собой математическую модель (рис. 1), имитирующую деятельность нервных клеток головного мозга. НС включает в себя непосредственно нейроны — узлы НС с заданной функцией активации, которая формирует выходной сигнал, а также связи между ними — синапсы. Все нейроны объединены в слои, каждый из которых выполняет свою задачу.



НС позволяет определять веса входных сигналов искомой неизвестной функции, в чем заключается одна из ее задач — аппроксимация (Оборнев и др., 2020)

Процесс нахождения весов можно отождествить с процессом обучения, в ходе которого нейронами вычисляется выходной сигнал на основе входных данных при помощи функции активации. Выходной сигнал сравнивается с заданными целевыми значениями, в результате которого определяется величина ошибки, после чего это действие повторяется. В ходе итерационного процесса обучения происходит пересчет весов, при этом величина ошибки между заданными целевыми значениями и прогнозируемыми выходными значениями минимизируется. Таким образом, обучение НС является процессом корректировки весов в ходе множества итераций.

КРАТКАЯ ХАРАКТЕРИСТИКА АЛГОРИТМА РЕШЕНИЯ ОЗ ВЭЗ

Разработанный алгоритм включает в себя четыре этапа:

- 1) формирование обучающей выборки входных и выходных данных;
- 2) обучение НС поиску параметров отдельно взятого горизонта и их непосредственное определение;
- 3) комбинация параметров моделей геоэлектрических разрезов, решение ОЗ для каждой комбинации мощностей и удельных электрических сопротивлений слоев;
- 4) определение оптимального решения ОЗ и его геологическая интерпретация.

Формирование обучающей выборки. Для обучения НС решению ОЗ электроразведки методом ВЭЗ требуются наличие входных данных в виде значений кажущегося сопротивления (КС) на определенных разносах зондирующей установки и выходных данных — целевых значений удельного электрического сопротивления и мощности для каждого слоя геоэлектрического разреза. Формирование обучающей выборки происходило на основе априорно заданной модели

Рис. 1. Схематичное представление многослойной НС, состоящей из трех слоев, содержащих, в общей сумме, 9 нейронов и 20 синапсов. На входной слой подаются элементы вектора входных данных, которые переопределяются по нейронам скрытого слоя. В результате на выходном слое формируются элементы выходного вектора.

Fig. 1. Schematic representation of a multilayer NN, consisting of three layers, containing a total of 9 neurons and 20 synapses. The input layer is fed with elements of the input data vector, which are redefined by the neurons of the hidden layer. As a result, elements of the output vector appear on the output layer.

начального приближения изучаемого разреза. К этой модели автоматически добавлялись новые параметры, близкие по значениям к начальному приближению, но осложненные случайной помехой, ограниченной некоторым диапазоном. Далее для всего множества сгенерированных моделей (порядка 200) решалась прямая задача ВЭЗ, в результате которой получен массив значения КС.

На эффективность обучения НС влияют количество моделей в массиве и выбор начальных параметров. Требуется достаточно широкое разнообразие начальных параметров, обеспечивающих различие обучающих моделей, которые должны отвечать всем реальным физико-геологическим ситуациям в рамках поставленной задачи.

Обучение НС. После того, как массив моделей окончательно сформирован, начинается процесс обучения НС. Как правило, обучение НС в задачах построения регрессии и многомерной классификации происходит однократно, веса полученные в ходе обучения затем используются во всех частных случаях (Гудфеллоу и др., 2018). Однако, применительно к электроразведке ВЭЗ, данный подход требует наличия массива, состоящей из огромного количества разнообразных моделей с отличающимися геоэлектрическими параметрами и различными геометрическими характеристиками измерительных установок. На практике, получение такого объема данных является слишком трудоемким процессом, а вопрос об универсальности и эффективности НС, обученной на основе такого рода обучающего массива, остается открытым. Кроме того, данный подход требует использования сложного типа НС, которые должны иметь возможность перестраивать свою структуру — менять количество нейронов и слоев.

Ввиду сказанного, по мнению авторов, имеет смысл обучать НС каждый раз для решения конкретной геологической задачи. Данный подход будет отличаться большей гибкостью и эффективностью, а также относительной простотой структуры НС. Однако он характеризуется большими затратами времени и, следовательно, меньшей производительностью ввиду необходимости обучения НС для решения каждой конкретной задачи. На обучение НС может уйти от трех до 15 минут и более в зависимости от степени изменчивости геоэлектрического разреза участка исследований, и опционально от количества слоев и решений ОЗ для каждой точки зондирования.

Зависимость между количеством слоев геоэлектрического разреза и временем обучения обусловлена тем, что корректировка весов НС проводится для отдельного слоя. То есть для

одного и того же набора КС сначала определяются параметры первого слоя, затем — второго слоя, третьего и т.д. Обучение НС для отдельного слоя позволяет использовать большее количество нейронов на каждый геоэлектрический горизонт. Такое условие носит рекомендательный характер и применяется с целью повышения эффективности корректировки весов НС.

Как было сказано, обучение НС также зависит от количества решений i для каждой кривой ВЭЗ. Число i задается оператором перед обучением нейронной сети и фактически означает то, сколько раз НС будет обучена решению ОЗ. Например, если число i равно 3, то НС будет обучено три раза, и для каждой точки ВЭЗ будет найдено три решения (модели). Аналогично ситуации с количеством слоев, такое условие носит рекомендательный характер и направлено на повышение эффективности корректировки весов. Кроме того, данный подход позволяет создать множество решений ОЗ, с которыми можно оперировать в дальнейшем.

Данный этап является ключевым для всего алгоритма, поскольку достоверность решения ОЗ во многом зависит от качества обучения нейронной сети, которое, в свою очередь, определяется архитектурой НС. Архитектуру нейронной сети можно описать как последовательность трех связанных между собой слоев:

- входного слоя;
- промежуточного скрытого слоя;
- выходного слоя.

Размер входного слоя равен количеству разностей АВ установки ВЭЗ — на каждый нейрон подается значение КС, отвечающее определенному разному. Нейроны входного слоя не производят вычислений, поэтому функция активации отсутствует.

Скрытый слой включает 5 нейронов, однако данное число может быть увеличено до 30 в сложных случаях. Данный слой необходим для промежуточных вычислений, придающих НС универсальности и гибкости. В качестве функции активации используется сигмоида — монотонно возрастающая нелинейная функция, горизонтальные асимптоты которой равны 0 и 1, что дает возможность нормализовать выходные значения искомых параметров, тем самым уменьшить вероятность появления отрицательных чисел.

Число нейронов выходного слоя зависит от количества выходящих параметров (мощностей h и сопротивлений ρ слоев), а также от способа обучения. Если НС обучается однократно, то количество нейронов будет тождественно суммарному количеству выходных параметров, например, для трехслойного разреза число нейронов будет равно 5 ($h_1, h_2, \rho_1, \rho_2, \rho_3$). В том случае, когда

НС обучается отдельно для нахождения параметров каждого геоэлектрического горизонта, число нейронов будет либо равно 2 (h_i, ρ_i), либо 1 — при определении сопротивления опорного горизонта. В данном слое используется функции активации типа Exponential Linear Unit (Clevert et al., 2016), которая также является нелинейной и монотонно возрастающей, но имеет область значений от -1 до ∞ , и, в целом, хорошо подходит при решении задач, связанных с аппроксимацией.

Для оценки качества обучения НС нами были построены графики зависимостей значений функции потерь от номера итерации на данных обучающей и тестовой выборок (рис. 2).

В качестве функции потерь использовалась средняя абсолютная ошибка в процентах (Mean Absolute Percentage Error, MAPE), которая вычисляется по формуле:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} * 100 ,$$

где y_i и \hat{y}_i — заданное значение и значение, полученное с помощью НС соответственно, n — количество значений (Keras..., 2023).

В случае, когда графики этих зависимостей начинают расходиться, происходит «переобучение» НС, которое приводит к снижению гибкости и универсальности нейронной сети. Данное явление возникает связи с тем, что в качестве обучающей выборки использован небольшой однотипный набор данных, который нуждается в расширении. Однако в контексте данного исследования определение «переобученности» НС не столь важно, поскольку НС может повторно обучаться множество раз, в том числе и по инициативе интерпретатора.

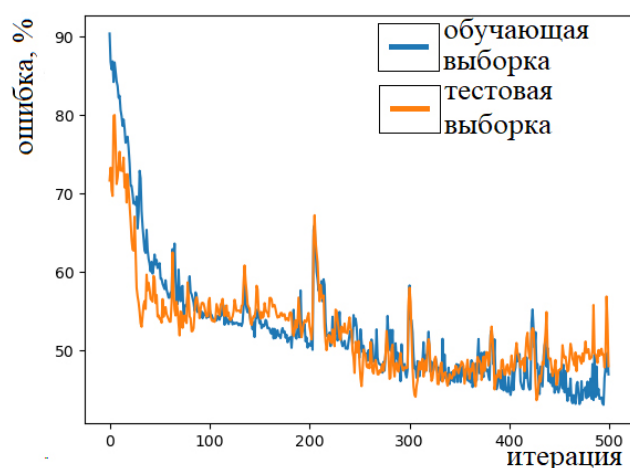


Рис. 2. Графики зависимостей значений функции потерь от номера итерации на данных обучающей и тестовой выборок.

Fig. 2. Graphs of the dependences of the loss function values on the number of iteration on the data of training and test samples.

Комбинирование параметров моделей. После нейросетевой аппроксимации создается множество решений путем комбинирования параметров моделей. Комбинирование представляет собой процесс нахождения новых решений путем последовательного перебора параметров моделей, полученных с помощью НС (рис. 3). Например, заменив параметры последнего слоя одной модели на параметры того же слоя другой модели, получим новое отличное от «родительских» моделей решение. Повторив данное действие множество раз (рис. 4), можно сформировать новую область решений, состоящую из k решений-комбинаций.

В общей сумме количество решений-комбинаций k определяется по формуле:

$$k = i^n,$$

где i — количество полученных НС эквивалентных моделей для одного пикета, n — количество слоев. Для каждой такой комбинации параметров решается прямая задача ВЭЗ (ПЗ ВЭЗ) и между полученными теоретическими значениями и наблюдаемыми данными вычисляется величина расхождения (невязки) σ по следующей формуле:

$$\sigma = \frac{\sum_{i=1}^r |(\rho_{ti} - \rho_{oi}) / (\rho_{ti} + \rho_{oi})| * 100}{r} ,$$

где ρ_{ti} и ρ_{oi} — конкретное значение КС теоретических и наблюдаемых данных соответственно, r — количество разносов АВ.

В случае, когда невязка меньше некоторого порогового значения, программой запоминаются параметры соответствующей модели и данное значение невязки с целью использования в дальнейшем.




Рис. 3. Пример, включающий три модели с начальным набором данных, полученных с помощью НС. Каждая модель является конкретным решением обратной задачи для одного пикета и состоит из четырех ячеек, которые соответствуют отдельным слоям разреза. Таким образом, в рамках данного примера, создано три модели, состоящие из четырех слоев.

Fig. 3. An example including three models with an initial NN dataset. Each model represents a specific solving the inverse problem solution for one picket and consists of four cells that orrespond to individual layers of the section. Thus, in this example, three models consisting of 4 layers were created.




Рис. 4. Схематичное представление процесса комбинации. У 1-ой модели изменяется сопротивление последнего слоя на сопротивление последнего слоя 2-ой модели, затем — на сопротивление последнего слоя 3-ей модели. После чего у первой модели с ее изначальными параметрами изменяются значения мощности и сопротивления предпоследнего слоя. В дальнейшем у «новой» первой модели заменяется сопротивление последнего слоя по вышеописанному алгоритму. Процесс повторяется до тех пор, пока параметры модели не станут идентичны параметрам последней модели, т.е. пока не будут перебраны параметры каждого слоя всех моделей.

Fig. 4. Schematic representation of the combination process. The resistance of the last layer of the 1st model changes to the resistance of the last layer of the 2nd model, then to the resistance of the last layer of the 3rd model. After that, the first model with its initial parameters changes the power and resistance values of the penultimate layer. Further, the resistance of the last layer of the «new» first model is changed according to the algorithm described above. The process is repeated until the model parameters become identical to the parameters of the last model, i.e. until the parameters of each layer of all models are sorted out.

Определение оптимального решения. После того, как сформировано множество решений ПЗ ВЭЗ, невязка которых ниже некоторого порогового значения, встает задача выбора оптимального решения. В качестве такого решения может выступать конкретная модель, характеризующаяся наименьшим значением невязки. Однако в таком случае существует риск, что полученное решение будет аппроксимировать не только полезную составляющую в измеренных значениях КС, но также помеху.

Ввиду этого в качестве оптимального решения предлагается использовать средние значения сопротивлений и мощностей геоэлектрического разреза, определенные по множеству комбинаций, невязка которых ниже порогового значения.

Нужно отметить, что статистический анализ множества допустимых решений успешно используется в аддитивных технологиях решения обратных задач гравиразведки и магниторазведки (Балк, Долгаль, 2020). Осреднение серии приближенных решений систем алгебраических уравнений было предложено В.Н. Страховым и применялось при построении аналитических аппроксимаций геофизических полей (Степанова и др., 2020). Имеется также опыт интерпретации данных ВЭЗ путем перебора решений ОЗ

при отсутствии жестких ограничений на закон распределения помехи, с предположением о близости к нулю ее медианного значения (Долгаль и др., 2020).

После нахождения средних значений параметров следует вычислить стандартные отклонения и определить доверительные интервалы. Помимо математических ожиданий можно использовать модальные значения параметров. Также допускается использование различных типов функционалов невязки.

В условиях, когда геологический разрез представлен близкими по вертикальной мощности горизонтами, целесообразно подбирать такие решения ОЗ ВЭЗ, в которых геометрические параметры изменяются незначительно.

АПРОБАЦИЯ СОЗДАННОГО АЛГОРИТМА

Далее рассмотрим результаты применения созданного алгоритма на синтетических примерах и практических полевых материалах. В синтетическом примере профиль ВЭЗ включает 10 точек зондирования, находящихся на расстоянии 100 м друг от друга. Геологический разрез состоит из трех горизонтов: верхний горизонт представлен насыпным грунтом, нижний — глинистыми отложениями, опорный — скальным грунтом. Значения КС осложнены помехой с величиной до 7% от полезного сигнала. С помощью НС были определены значения параметров заданной модели, которые затем сопоставлялись с исходными (табл. 1). Для всех найденных решений ОЗ ВЭЗ невязка изменяется в диапазоне от 3 до 8 %.

Следует отметить, что решение с наименьшей невязкой не всегда является наилучшим с точки зрения определения параметров геоэлектрического разреза. В качестве примера проанализируем мощность 2 слоя 10-й точки ВЭЗ: мощность, определенная как среднее значение мощностей множества решений, составляет 22.94 м, мощность, соответствующая решению с наименьшей невязкой, составляет 21.69 м, в то время как истинная мощность составляет 28.60 м. В общей сложности в 60 из 100 случаев решение, найденное через средние значения параметра ближе к исходным значениям, чем решение, соответствующее минимальной невязке. Данный вывод подтверждает, что решение с минимальной невязкой не всегда оказывается наиболее достоверным.

В программе «ЗОНД» (Колесников, 2007) была выполнена интерпретация кривых ВЭЗ, отвечающих исходной геоэлектрической модели и новой модели, характеристики которой определены как средние значения всего множества

решений ОЗ ВЭЗ с применением НС (рис. 5, 6). Морфология геоэлектрических горизонтов для двух этих моделей в целом достаточно близка, особенно слабо отличаются параметры верхнего слоя (мощность и сопротивление).

Апробация алгоритма выполнена на материалах, полученных в ходе полевых наблюдений вблизи пос. Октябрьский в Пермском крае (рис. 7). Целью профильных инженерно-геофизических изысканий являлось определение

Таблица 1. Значения исходных параметров и параметров, определенных в результате решения ОЗ ВЭЗ с помощью НС

Table 1. Values of initial parameters and parameters determined as a result of solving the VES IP using a NN

№	Значения	$h_1, \text{ м}$	$\rho_1, \text{ Ом}\cdot\text{м}$	$h_2, \text{ м}$	$\rho_2, \text{ Ом}\cdot\text{м}$	$\rho_3, \text{ Ом}\cdot\text{м}$	$\sigma_{\text{ср}}, \%$
1	истинные ¹	13.54	300	23.62	31	3000	-
	средние ²	12.51	318	22.05	29	2252	3.6
2	истинные	12.30	264	19.72	31	2283	-
	средние	11.64	270	21.07	30	2252	4.6
3	истинные	10.16	323	17.14	29	3312	-
	средние	9.39	328	17.75	34	2252	3.7
4	истинные	8.57	383	17.59	33	2854	-
	средние	8.22	390	18.88	32	2252	3.9
6	истинные	6.17	430	20.85	36	2235	-
	средние	5.99	422	18.99	32	2252	4.9
7	истинные	5.37	355	26.65	28	2794	-
	средние	5.03	363	25.18	23	2252	4.8
8	истинные	6.71	344	28.15	29	2283	-
	средние	6.48	362	25.36	23	2252	5.0
9	истинные	9.33	363	28.62	30	2357	-
	средние	8.65	374	23.60	25	2252	4.5
10	истинные	12.70	371	28.60	35	2433	-
	средние	12.36	369	22.94	28	2252	4.3
	минимальные ³	12.85	356	21.69	28	2136	3.4
	лучшие ⁴	12.36	369	27.46	31	2252	4.1

Примечание. ¹ — значения параметров заданной модели, ² — значения, полученные путем осреднения всех решений, ³ — значения, соответствующие решению с наименьшей невязкой, ⁴ — значения, которые выбраны на основе сравнения с параметрами заданной модели.

Note. ¹ — values of parameters of the given model, ² — values obtained by averaging all solutions, ³ — values corresponding to the solution with the smallest discrepancy, ⁴ — values selected on the basis of comparison with the parameters of the given model.

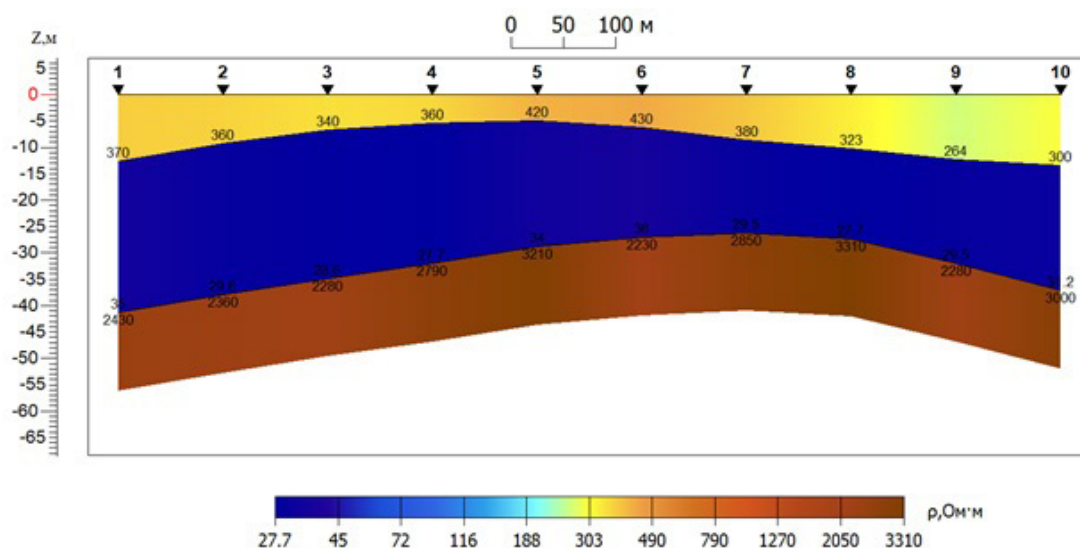


Рис. 5. Заданная модель геоэлектрического разреза.

Fig. 5. Specified geoelectricsection model.

ВОЗМОЖНОСТИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ




Рис. 6. Модель, полученная с помощью НС и отражающая осредненные значения всех решений.
Fig. 6. A model obtained using an NN and reflecting the average values of all solutions.

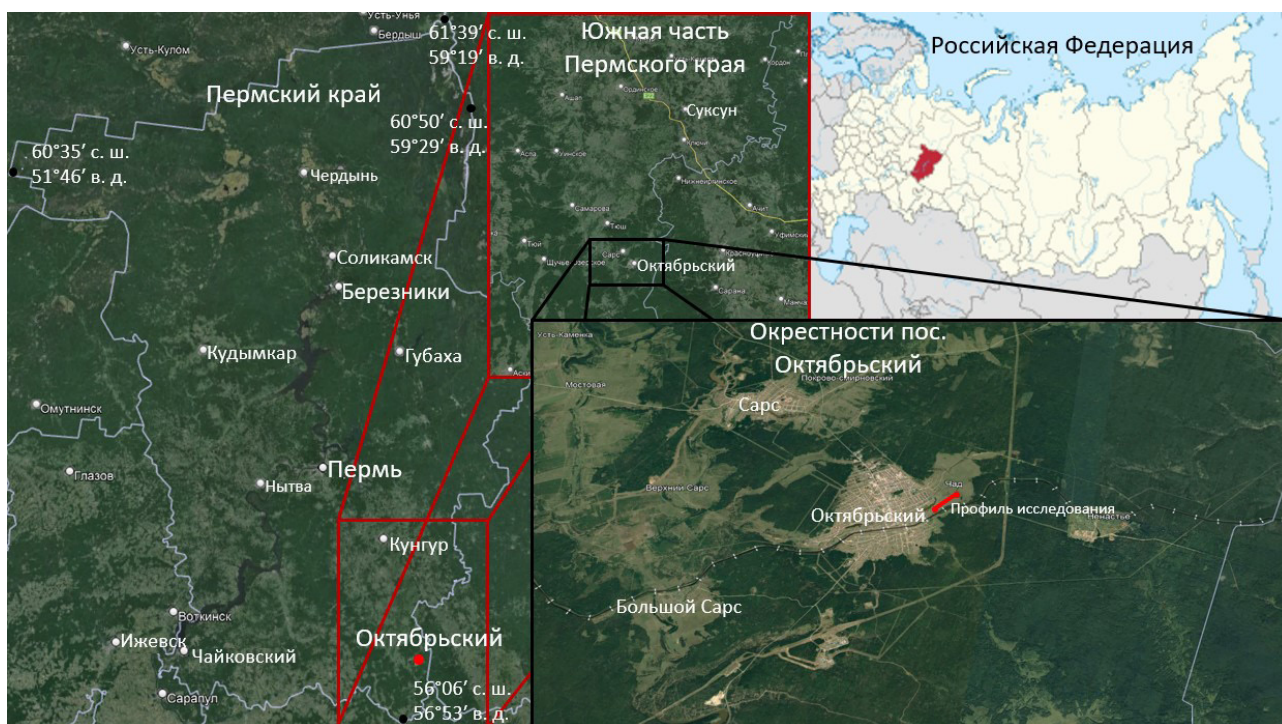


Рис. 7. Карты Российской Федерации, Пермского края, южной части Пермского края и окрестностей пос. Октябрьский с выделенным профилем работ.
Fig. 7. Maps of the Russian Federation, the Perm region, the southern part of the Perm region and the environs of the Oktyabrsky village with the highlighted work profile.

глубины залегания кровли коренных пород, имеющих преимущественно карбонатный состав. В установке ВЭЗ использовались следующие полуразносы АВ/2: 1.6; 2.0; 2.5; 3.2; 4.0; 5.0; 6.3; 8.0; 10.0; 12.5; 16.0; 20.0; 25.0; 32.0; 40.0; 50.0; 63.0; 80.0; 100.0; 125.0; 160.0, в м. Размеры приемной линии MN составляли 1 и 10 м. Точки зондирования находились на расстоянии 100 м друг от друга, профиль исследований включал в себя 28 точек.

При решении ОЗ ВЭЗ невязка изменяется в широких диапазонах — от 5% до 20% (табл. 2), что объясняется более сложным геологическим строением и высоким уровнем помех. Наблюдается тенденция понижения невязки к центру профиля, которая обусловлена тем, что для формирования начального приближения геоэлектрической модели использовались данные о разрезе скважины, которая находилась в центре профиля. Значения невязки удавалось

Таблица 2. Результаты решения обратной задачи для наблюдаемых данных

Table 2. Results of the solving the inverse problem for observed data

№	$h_1, \text{ м}$	$\rho_1, \text{ Ом}\cdot\text{м}$	$h_2, \text{ м}$	$\rho_2, \text{ Ом}\cdot\text{м}$	$\rho_3, \text{ Ом}\cdot\text{м}$	$\sigma_{\text{ср}}, \%$
23	0.85	222	32.25	45	551	14.85
24	0.85	222	31.86	46	542	15.72
25	0.82	215	31.68	45	535	15.28
26	0.79	206	30.82	45	538	16.01
27	0.63	184	28.22	44	500	14.67
28	0.54	160	27.41	44	511	14.90
29	0.43	109	22.18	41	494	13.35
30	0.40	87	24.50	42	532	16.04
31	0.35	74	22.95	42	514	14.08
32	0.32	55	22.55	42	506	13.08
33	0.38	65	17.77	40	489	7.19
34	0.48	100	19.64	41	534	9.49
35	0.55	117	17.71	40	538	9.04
36	0.57	150	15.49	40	521	8.34
37	0.58	153	16.44	40	536	9.73
38	0.47	98	17.59	41	535	10.84
39	0.44	83	17.07	41	532	10.69
40	0.31	41	15.86	40	500	8.22
41	0.22	22	16.10	40	490	12.82
42	0.22	23	15.09	39	476	10.97
43	0.23	25	17.45	39	485	11.56
44	0.24	29	15.72	38	459	10.49
45	0.24	28	17.36	38	451	12.54
46	0.25	31	15.73	37	451	12.10
47	0.27	38	15.12	36	450	11.00
48	0.30	43	14.89	36	459	12.15
49	0.27	39	14.17	35	452	13.17
50	0.28	39	15.02	36	454	11.72

уменьшить путем подбора лучшего начального приближения, увеличения количества выделяемых слоев, создания большей по объему и более разнообразной обучающей выборки.

Разрезы (рис. 8, 9), построенные по наблюдаемым данным традиционным способом (1D-интерпретация с использованием программы ЗОНД) и с помощью НС, отличаются по форме, мощностям и сопротивлениям. При использовании НС максимальная глубина геоэлектрического разреза увеличилась на 10–12 м, что более точно отражает эффективную глубину зондирования, равную 1/4–1/6 от AB_{max} .

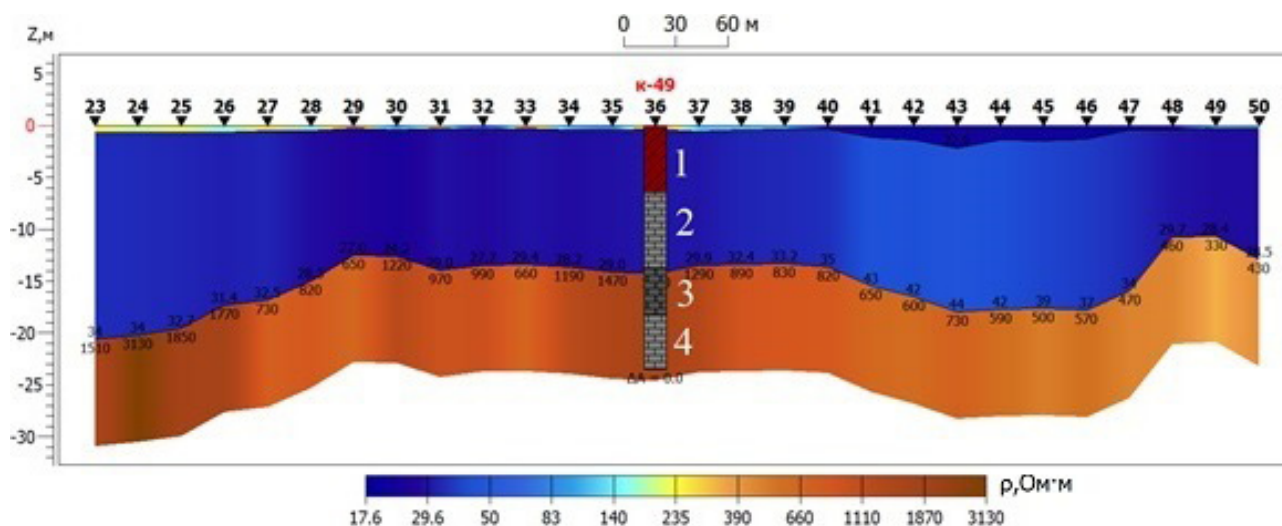
На обоих разрезах наблюдается закономерное увеличение глубины залегания кровли опорного горизонта, однако для разреза, построенного с помощью НС, приращение глубинности происходит более интенсивно.

Первый разрез отличает то, что сопротивления последнего слоя его правой части имеют значение несколько ниже, чем сопротивления центральной и левой части. Второй разрез обладает менее контрастным понижением в значениях сопротивлений, что является существенным недостатком решения, полученного с помощью НС.

Помимо сказанного, НС с высокой долей погрешности определяет удельное электрическое сопротивление последнего слоя, что, вероятно,

Рис. 8. Геоэлектрический разрез участка «Октябрьский», построенный традиционным способом (1D-интерпретация с использованием программы ЗОНД). Разрез представлен: 1 — отложения суглинков; 2 — известняки выветрелые; 3 — доломиты выветрелые; 4 — известняки плотные.

Fig. 8. Geoelectric section of the Oktyabrsky site, constructed in the traditional way (1D-interpretation using the ZOND program). The section is represented by: 1 — loam sediments; 2 — weathered limestones; 3 — weathered dolomites; 4 — dense limestones.



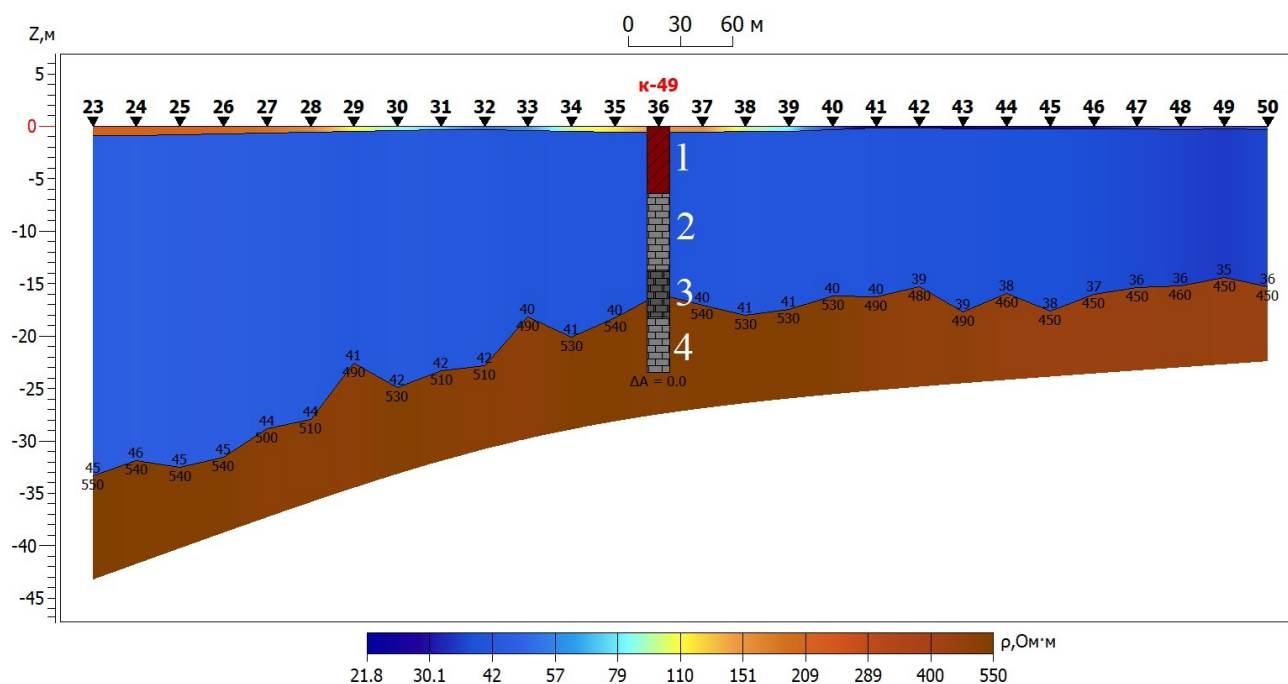


Рис. 9. Геоэлектрический разрез участка «Октябрьский», построенный с помощью НС. Разрез представлен: 1 — отложения суглинков; 2 — известняки выветрелые; 3 — доломиты выветрелые; 4 — известняки плотные.

Fig. 9. Geoelectric section of the «Oktyabr'skiy » site, constructed using an NN. The section is represented by: 1 — loam sediments; 2 — weathered limestones; 3 — weathered dolomites; 4 — dense limestones.

связано со сложными взаимосвязями между значениями кажущегося сопротивления всех разностей и удельного электрического сопротивления последнего слоя. Так опорный горизонт разреза, полученного при 1D-интерпретации, обладает сопротивлениями в диапазоне от 300 до 3000 Ом·м, в то время как сопротивления того же горизонта, определенные с помощью НС, составляют от 450 до 550 Ом·м.

ЗАКЛЮЧЕНИЕ

Решение ОЗ ВЭЗ с помощью алгоритма, представленного в настоящей работе, имеет как ряд преимуществ, так и ряд недостатков. К преимуществам выполненной программно-алгоритмической разработки можно отнести:

- полную автоматизацию процесса интерпретации;
- слабую зависимость времени моделирования геоэлектрического разреза от количества кривых ВЭЗ;
- представление результатов одним частным решением ОЗ, а множеством допустимых решений, отвечающих выбранному «коридору» невязки;
- широкий спектр возможностей применения алгоритма (различные типы разреза, изменяющееся количество разностей, разный уровень помех в измерениях).

К недостаткам можно отнести:

- чувствительность процесса обучения к начальному приближению;
- зависимость времени работы алгоритма от числа выделяемых слоев в геоэлектрическом разрезе;

Представленный алгоритм в дальнейшем можно совершенствовать с помощью внедрения новых технологий определения начального приближения для геоэлектрической модели, совершенствования процесса обучения НС, привлечения новых методик комбинации параметров слоев и различных подходов к анализу множества полученных допустимых решений ОЗ. В целом использование НС в области количественной интерпретации данных ВЭЗ является весьма перспективным направлением развития современных компьютерных технологий.

Список литературы [References]

Балк П.И., Долгаль А.С. Аддитивные технологии решения обратных задач гравиразведки и магниторазведки. М.: Научный мир, 2020. 455 с. [Balk P.I., Dolgal A.S. Additive methods for solving inverse problems of gravity and magnetic prospecting. Moscow: Nauchnyy mir. 2020. 455 p.]

Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / перевод с англ., М.: ДМКПресс, 2018, 652 с. [Goodfellow Ya., Bengio Yo., Courville A. Deep Learning. Moscow: MIT Press, 2016. 781 p.]

Долгаль А.С., Тайницкий А.А., Христенко Л.А. Реализация концепции минимизации эмпириче-

- ского риска в обратной задаче ВЭЗ // Вестник КРАУНЦ. Науки о Земле. 2020. № 1. Вып. 45. С. 38–48 [Dolgal A.S., Tainitsky A.A., Khristenko L.A. The implementation of the concept of empirical risk minimization in the VES inverse problems // Vestnik KRAUNTs. Earth Sciences. 2020. № 1 (45). P. 38–48 (in Russian)].
- Костиков Д.В. Инструментальные средства интерпретации геофизических исследований скважин на основе преобразованных каротажных диаграмм с помощью многослойной нейронной сети: Автореф. дисс. канд. техн. наук. Ижевск, 2007, 24 с. [Kostikov D.V. Instrumental'nyye sredstva interpretatsii geofizicheskikh issledovaniy skvazhin na osnove preobrazovannykh khkarotazhnykh diagramm s pomoshch'yu mnogoslounoy neyronnoy seti: Avtoref. diss. kand. tekhn. nauk. Izhevsk, 2007, 24 p.].
- Колесников В.П. Основы интерпретации электрических зондирований. М.: Научный мир, 2007. 248 с. [Kolesnikov V.P. Basics of interpretation of electrical soundings. Moscow: Nauchnyy mir. 2007. 248 p.].
- Московский И.Г., Балабан О.М., Федорова О.С. и др. Применение нейронных сетей при интерпретации данных электромагнитных зондирований вертикально-трещиноватых сред // Наукovedenie. 2015. Т. 7. № 1. С. 1–12. <https://doi.org/10.15862/05TVN115> [Moskovsky I.G., Balaban O.M., Fedorova O.S. et al. Application of neural networks at interpretation of these electromagnetic sounding of vertically jointed environments // Naukovedenie 2015. V. 7. № 1. P. 1–12 (in Russian)].
- Оборнев И.Е. Повышение эффективности интерпретации данных МТЗ на основе использования нейронных палеток: Автореф. дисс. канд. физ.-мат. наук. Москва, 2013. 18 с. [Obornev I.Ye. Povysheniye effektivnosti interpretatsii dannykh MTZ na osnove ispol'zovaniya neyronnykh paletok: Avtoref. diss. kand. fiz.-mat. nauk. Moscow, 2013, 18 p. (in Russian)].
- Оборнев Е.А., Оборнев И.Е., Родионов Е.А., Шимелевич М.И. Применение нейронных сетей в нелинейных обратных задачах геофизики // Журнал вычислительной математики и математической физики. 2020. Т. 60. № 6. С. 1053–1065. <https://doi.org/10.31857/S0044466920060071> [Obornev Ye.A., Obornev I.Ye., Rodionov Ye.A., Shimelevich M.I. Application of neural networks in nonlinear inverse problems of geophysics // Computational Mathematics and Mathematical Physics. 2020. V. 60. Iss. 6. P. 1025–1036. <https://doi.org/10.1134/S096554252006007X>].
- Родина С.Н., Силкин К.Ю. Применение нейросетевого подхода при интерпретации каротажных данных // Вестник ВГУ. Геология. 2007. № 7. С. 184–188 [Rodina S.N., Silkin K.Yu. Application of artificial neural networks for well-log data interpretation // Vestnik VGU. Geologiya. 2007. № 7. P. 184–188 (in Russian)].
- Степанова И.Э., Керимов И.А., Раевский Д.Н., Щенетлов А.В. О совершенствовании методов обработки больших объемов данных в геофизике и геоморфологии на основе модифицированных S- и F-аппроксимаций // Физика Земли. 2020. № 3. С. 82–97. <https://doi.org/10.31857/S0002333720030114> [Stepanova I.E., Kerimov I.A., Raevskiy D.N. et al. Improving the methods for processing large data in geophysics and geomorphology based on the modified S- and F-approximations // Izvestiya, Physics of the Solid Earth. 2020. Iss. 3. P. 82–97. <https://doi.org/10.1134/S1069351320030118>].
- Шайбаков Р.А. Обоснование комплексной методики идентификации трехмерных геологических объектов: Автореф. дисс. канд. геол.-мин. наук. Уфа, 2014, 25 с. [Shaybakov R.A. Obosnovaniye kompleksnoy metodiki identifikatsii trekhmernykh geologicheskikh ob'yektov: Avtoref. diss. kand. geol.-min. nauk. Ufa, 2014, 25 p.].
- Шимелевич М.И. Применение методов искусственного интеллекта (нейронных сетей) в обратных нелинейных задачах геофизики с приложением к геоэлектрике // VIII Всероссийская школа-семинар ЭМЗ-2021. Москва. 2021. С. 20–26 [Shimelevich M.I. Primeneniye metodov iskusstvennogo intellekta (neyronnykh setey) v obratnykh nelineynykh zadachakh geofiziki s prilozheniyem k geoelektrike // VIII Vserossiyskaya shkola-seminar EMZ-2021. Moscow. 2021. P. 20–26].
- Шимелевич М.И., Оборнев Е.А., Оборнев И.Е., Родионов Е.А. Алгоритм решения обратной задачи геоэлектрики на основе нейросетевой аппроксимации // Сибирский журнал вычислительной математики. 2018. Т. 21. № 4. С. 451–468. <https://doi.org/10.15372/SJNM20180408> [Shimelevich M.I., Obornev Ye.A., Obornev I.Ye., Rodionov Ye.A. An algorithm for solving inverse geoelectrics problems based on the neural network approximation // Numerical analysis and applications. 2018. V. 21. Iss. 4. P. 451–468. <https://doi.org/10.1134/S1995423918040080>].
- Clevert D.-A., Unterthiner T., Hochreiter S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs) // International Conference on Learning Representations. 2016. <https://doi.org/10.48550/arXiv.1511.07289>
- Keras [Электронный ресурс]. URL: <https://keras.io/> (accessed 15.10.2023).
- Rücker C., Günther T., Wagner F.M. pyGIMLi: An open-source library for modelling and inversion in geophysics // Computers and Geosciences. 2017. P. 106–123, <https://doi.org/10.1016/j.cageo.2017.07.011>.

ВОЗМОЖНОСТИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ
**POSSIBILITIES OF ARTIFICIAL NEURAL NETWORKS
IN SOLVING INVERSE PROBLEMS OF ELECTRICAL PROSPECTING
BY THE METHOD OF VERTICAL ELECTRICAL SOUNDING**

R.N. Petrosyan, N.V. Ryzhov

Perm State National Research University, Perm, Russia, 614068; e-mail: petrosyan@antikarst.ru

Received December 21, 2023; revised May 07, 2024; accepted June 25, 2024

An algorithm for solving the inverse problem of electrical prospecting by the method of vertical electrical sounding (VES) using neural networks (NN) is presented. The use of NN is aimed at identifying complex patterns and dependencies that may not be available for traditional methods of quantitative interpretation of electrical prospecting data. The algorithm includes the formation of a training sample; training NN and directly obtaining solutions; combination of solutions found with the help of NN and selection of the optimal solution to the inverse problem of VES. The algorithm is tested on model data and practical materials in order to evaluate its capabilities. Geoelectric sections constructed using NN based on the results of field observations were compared with the results of quantitative interpretation performed in the «ZOND» program. The advantages and disadvantages of the created algorithm for solving the inverse problem of VES, as well as ways for its further development are characterized.

Keywords: electrical prospecting; vertical electrical sounding; inverse problem; neural networks.