

Нейросетевая 3D инверсия полевых данных геоэлектрики

Е.А. Родионов¹, М.И. Шимелевич², И.Е. Оборнев³, Е.А. Оборнев⁴, И.С. Фельдман⁵

¹МГРИ, evgeny_980@list.ru

² МГРИ, shimelevich-m@yandex.ru

³ НИИЯФ МГУ, МГРИ, o_ivano@mail.ru

⁴ МГРИ, obornevea@mail.ru

⁵ЕМГЕО, mail@emgeo.com

АННОТАЦИЯ

Обратная задача МТЗ сводится к нелинейному операторному уравнению I рода и рассматривается в классе кусочно-постоянных функций, которые задают удельное сопротивление среды в ячейках заданной сетки параметризации. Общее число искомых параметров такой задачи может превышать 10^3 . Разработан алгоритм восстановления распределения удельного сопротивления трехмерной среды по данным МТЗ при помощи нейросетевого аппроксиматора, построенного на основе аппроксимационной конструкции типа многослойного персептрона. В качестве первого приближения решения обратной задачи принимается решение, полученное при помощи аппроксиматора, которое в дальнейшем уточняется методами случайного поиска. Работа алгоритма иллюстрируется на примере инверсии площадных полевых данных МТЗ.

Ключевые слова: Геофизика, геоэлектрика, МТЗ, 3D обратная задача, аппроксимация, нейронные сети, метод случайного поиска, полевые данные

ВВЕДЕНИЕ

Обратная задача магнитотеллурического зондирования (МТЗ) сводится к решению нелинейного операторного уравнения I рода в классе кусочно-постоянных решений, задаваемых на сетке параметризации θ_N размерности N . Аппроксимационный нейросетевой метод решения задачи (Obornev et al., 2020; Shimelevich et al., 2017) основан на построении приближенного обратного оператора задачи (нейросетевого аппроксиматора) с использованием нейросетевых конструкций типа многослойного персептрона. Это позволяет находить распределение логарифма удельного сопротивления среды в ячейках заданной сетки параметризации по наблюдаемым данным МТЗ e_m , $m = 1, \dots, M$, в аналитическом виде

$$\lg \rho_n \approx \sum_{l=1}^{L_n} v_s^{nl} \lambda_s \left(\dots \sum_{l=1}^{L_1} v_1^{nl} \lambda_1 \left(\sum_{m=1}^M w_1^{lm} e_m \right) \dots \right), \quad n = 1, \dots, N, \quad (1)$$

где v_i^{nl} , w_i^{lm} , $i = 1, \dots, s$, – коэффициенты нейронной сети, которые определяются в процессе ее обучения на основе заранее рассчитанного множества решений прямых и обратных задач, называемого «банком решений». Нелинейность в конструкции 1 задается передаточными функциями λ_i , $i = 1, \dots, s$.

МЕТОДЫ

Для нахождения коэффициентов нейронной сети v_i^{nl} , w_i^{lm} , $i = 1, \dots, s$, решается следующая оптимизационная задача обучения нейронной сети

$$\sum_{p=1}^P \sum_{n=1}^N \left[\lg \rho_n^p - \sum_{l=1}^{L_s} v_s^{nl} \lambda_s \left(\dots \sum_{l=1}^{L_1} v_1^{nl} \lambda_1 \left(\sum_{m=1}^M w_1^{lm} e_m^p \right) \dots \right) \right]^2 \xrightarrow{v_i^{nl}, w_i^{lm}} \min, \quad (2)$$

где N – число параметров среды, P – объем банка решений. Расчет банка решений задача весьма трудоемкая, однако, это необходимо сделать всего один раз для заданного класса сред. После нахождения коэффициентов нейронной сети построенный нейросетевой аппроксиматор тестируется на независимой тестовой выборке известных решений обратных задач, которые не использовались при обучении; таким образом, вычисляется собственная (интерполяционная) ошибка аппроксиматора. После решения оптимизационной задачи 2 решение обратной задачи по формуле 1 занимает доли секунды.

После получения первого нейросетевого приближения проводится кластеризация полученного распределения параметров среды, и рассчитывается множество решений в окрестности найденного с учетом пространственных границ полученных

кластеров. За второе приближение принимается решение из этого множества с минимальной невязкой (меньшей, чем на предыдущей итерации). Эта процедура повторяется до тех пор, пока не будет найдено ни одного решения с меньшей невязкой в окрестности решения на предыдущей итерации.

РЕЗУЛЬТАТЫ

В качестве модельного класса сред была выбрана пятислойная блочная модель с горизонтальными размерами 15x15км. Мощности слоев составляют 50, 80, 250, 750 и 2000м. В силу затухания поля с глубиной размеры блоков с глубиной увеличиваются. На 1-м слое количество параметров модели среды составляет 900, на 2-м, 3-м и 4-м – по 100 и на 5-м – 25. Таким образом общее число искомым параметров данной модели – 1225.

Изложенный выше метод решения обратной задачи был успешно оттестирован на модельных данных для описанного выше класса сред.

В качестве инвертируемых полевых данных были выбраны площадные МТ наблюдения участка Северо-Пясинской площади, которые являются частью региональной съемки Енисей-Хатангского прогиба. Данные, полученные ООО ЕМГЕО, представляют собой действительные и мнимые части четырех компонент тензора импеданса и двух компонент вектора Визе-Паркинсона (типпера) в диапазоне периодов $T=0.0046-631$ с, шаг по пикетам и профилям примерно 500м. Площадь наблюдения составляет 4.5x5км и включает 10 профилей. После получения первого нейросетевого приближения было проделано 5 итераций, в результате чего площадная невязка уменьшилась с 18.7% до 8.84%. Результаты инверсии (рисунок 1) качественно согласуются с инверсией, проведенной ООО ЕМГЕО, значения

найденных параметров среды в среднем различаются на 13.73%.

Выводы

Получены первые удовлетворительные результаты 3D нейросетевой инверсии полевых данных геоэлектрики в классе кусочно-постоянных сред с дальнейшим уточнением решений методом случайного поиска. Порядок числа искомым параметров составил $\sim 10^3$.

Благодарности

Работа выполнена с использованием вычислительных ресурсов Межведомственного суперкомпьютерного центра Российской академии наук (МСЦ РАН) и с использованием оборудования Центра коллективного пользования сверхвысокопроизводительными вычислительными ресурсами МГУ имени М.В. Ломоносова.

Исследование выполнено при поддержке РФФИ, проект №19-01-00738.

ЛИТЕРАТУРА

Obornev, EA., Obornev, IE., Rodionov, EA, Shimelevich MI, 2020. Application of Neural Networks in Nonlinear Inverse Problems of Geophysics. *Comput. Math. and Math. Phys.* 60, 1025–1036.

doi:[10.1134/s096554252006007x](https://doi.org/10.1134/s096554252006007x)

Shimelevich MI, Obornev EA, Obornev IE, Rodionov EA, 2017. The neural network approximation method for solving multidimensional nonlinear inverse problems of geophysics. *Izv., Phys. Solid Earth* 53, 588–597.

doi:[10.1134/S1069351317040097](https://doi.org/10.1134/S1069351317040097)

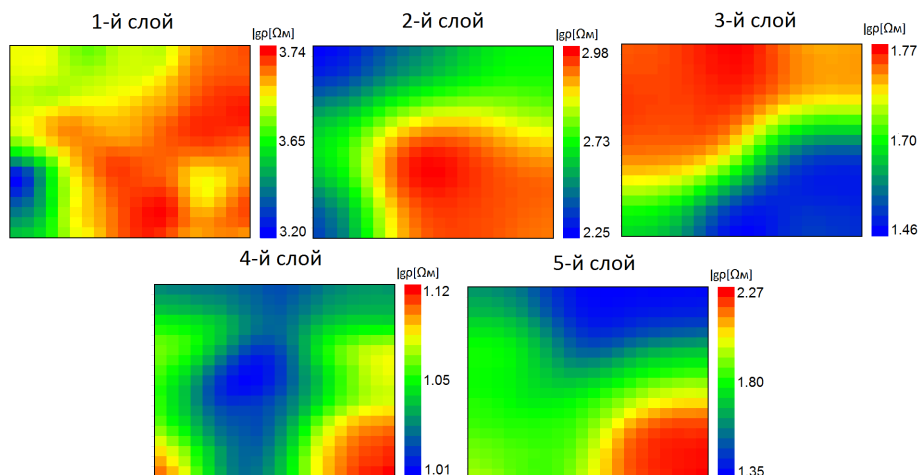


Рисунок 1. Распределение удельного сопротивления 5-ти горизонтальных срезов, полученное после проведения 6-й итерации, по данным Северо-Пясинской площади.