

Сравнение методов комплексирования данных при нейросетевом решении обратной задачи разведочной геофизики

И.В. Исаев
Московский государственный
университет
имени М.В. Ломоносова,
НИИ ядерной физики
имени Д.В. Скобельцына
Москва, Россия
isaev_igor@mail.ru

И.Е. Оборнев
Московский государственный
университет
имени М.В. Ломоносова,
НИИ ядерной физики
имени Д.В. Скобельцына
Москва, Россия
o_ivano@mail.ru

Е.А. Оборнев
Российский государственный
геологоразведочный университет
имени Серго Орджоникидзе
Москва, Россия
eugenyo@mail.ru

Е.А. Родионов
Российский государственный
геологоразведочный университет
имени Серго Орджоникидзе
Москва, Россия
evgeny_980@list.ru

М.И. Шимелевич
Российский государственный
геологоразведочный университет
имени Серго Орджоникидзе
Москва, Россия
Shimelevich-M@yandex.ru

С.А. Доленко
Московский государственный
университет
имени М.В. Ломоносова,
НИИ ядерной физики
имени Д.В. Скобельцына
Москва, Россия
dolenko@srd.sinp.msu.ru

Аннотация— Обратные задачи (ОЗ) разведочной геофизики (РГ) заключаются в восстановлении пространственного распределения свойств среды в толще Земли по измеренным на ее поверхности геофизическим полям. В частности, в настоящей работе рассматриваются ОЗ гравиметрии, магнитометрии и электроразведки (магнитотеллурического зондирования), а также их комплексирование, т.е. одновременное использование нескольких геофизических полей для восстановления искомого распределения. В настоящей работе сравниваются между собой результаты нейронных сетей, непосредственно обученных на данных сразу нескольких геофизических методов, с результатами стекинга нейронных сетей, обученных на данных каждого геофизического метода по отдельности.

Ключевые слова— обратные задачи, разведочная геофизика, гравиметрия, магнитометрия, магнитотеллурическое зондирование, комплексирование данных, искусственные нейронные сети, стекинг.

1. ВВЕДЕНИЕ

ОЗ РГ в общем случае имеют ряд особенностей, осложняющих их решение: высокая размерность по входу и выходу, нелинейность, некорректность и плохая обусловленность. Традиционными методами их решения являются оптимизационные методы, основанные на многократном решении прямой задачи с минимизацией невязки в пространстве наблюдаемых полей, и матричные методы с использованием регуляризации Тихонова. Главным недостатком оптимизационных методов является то, что из-за присущей данным ОЗ некорректности, малая невязка в пространстве наблюдаемых величин не гарантирует малую невязку в пространстве определяемых параметров. Недостатком матричных методов является то, что они относятся к линейным методам, поэтому при использовании их для решения нелинейных задач необходимо выполнить нелинейную предобработку данных. Поэтому в качестве альтернативы было предложено использовать

искусственные нейронные сети (НС), которые свободны от перечисленных выше недостатков.

Однако, и в случае применения НС некорректность ОЗ РГ влияет в негативную сторону на качество решения и повышает чувствительность решения к шумам в данных. Одним из способов снижения некорректности задачи является внесение дополнительной информации о рассматриваемом объекте. В частности, в настоящей работе рассматривается комплексирование данных, т.е. одновременное использование данных нескольких геофизических методов. Этот подход может быть реализован как в виде непосредственного обучения НС одновременно на данных нескольких геофизических методов, так и в виде стекинга, т.е. в виде обучения мета-алгоритма на ответах комитета НС, где каждая НС, входящая в комитет, обучалась на данных только одного геофизического метода, а в комитет входили сети, обученные на данных разных геофизических методов.

Целью настоящей работы являлось сравнение эффективности указанных выше подходов.

2. ПОСТАНОВКА ОБРАТНОЙ ЗАДАЧИ РАЗВЕДОЧНОЙ ГЕОФИЗИКИ

Для реализации нейросетевого решения необходимо задать исходное пространственное распределение свойств среды конечным числом определяемых параметров. При этом для реализации комплексирования данных требуется, чтобы определяемые параметры для всех используемых геофизических методов совпадали. В соответствии с этими требованиями была предложена 4-х слойная 2D-модель [1] (Рис. 1), где обратная задача заключалась в определении нижних границ слоев, а каждый слой характеризовался переменными значениями глубины нижней границы по разрезу и фиксированными значениями плотности, намагниченности и удельного электрического сопротивления как для слоя, так и для всего набора данных. Физические характеристики второго и четвертого слоев были одинаковыми.

Размеры разреза составляли 15 км в ширину и 3 км в глубину. Шаг измерения физических полей 0,5 км – 31 точка измерения по профилю. При этом входная размерность задачи составила 31, 31 и 62 признака для гравиметрии, магнитометрии и магнитотеллурического зондирования, соответственно. Дискретность изменения границ геологических слоев составляла 1 км – 15 значений глубин для каждого слоя. Определялись значения глубин нижних границ трех верхних слоев. Таким образом, выходная размерность задачи составила 45 определяемых параметров.

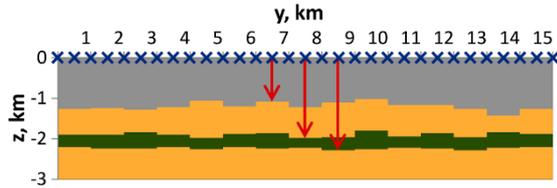


Рис. 1. Пример разреза. Маркеры (x) указывают места измерений геофизических полей, стрелки указывают места определения глубин слоев

Для каждого примера исходного набора данных случайным образом задавались значения глубины слоя в заданном диапазоне [1]. Далее конечно-разностными методами решалась прямая задача – для гравиметрии, магнитометрии и электроразведки. Всего было рассчитано 30 000 примеров.

3. ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

А. Данные

Исходный массив данных был разделен на тренировочный, валидационный и тестовый наборы в соотношении 70:20:10. Размерность наборов составила 21 000, 6 000 и 3 000 примеров, соответственно.

Б. Нейронные сети

Все используемые в работе НС представляли собой многослойные перцептроны с 1 скрытым слоем и 32 нейронами в нем. Для предотвращения переобучения использовался метод ранней остановки – обучение прекращалось спустя 500 эпох без улучшения результата на валидационном наборе. Для уменьшения влияния фактора, связанного с влиянием начальной инициализации весов на обучение, для каждого рассматриваемого случая обучалось по 5 НС, а статистические показатели их применения усреднялись.

Для уменьшения выходной размерности задачи использовалось т.н. автономное определение [1] параметров, заключающееся в индивидуальном определении каждого параметра путем обучения отдельной НС с одним выходом. Рассматривались результаты для параметров, находящихся на центральной вертикали (Рис. 1).

В. Комплексирование данных

В работе сравнивались результаты решения следующими методами:

- *Исходное решение* – нейронные сети обучались на данных только одного геофизического метода. Входная размерность задачи составляла 31 или 62 признака.

- *Комплексирование данных* – осуществлялось путем подачи на вход НС данных сразу нескольких геофизических методов. Входная размерность задачи при этом составляла 62, 93 или 124 признака.

- *Стекинг* – ответы НС, реализующих исходное решение, использовались в качестве входных признаков для обучения мета-алгоритма, в качестве которого также использовались НС с теми же параметрами обучения. Для каждого геофизического метода использовался комплект из 5 НС, таким образом, входная размерность задачи обучения мета-алгоритма составляла 10 или 15 признаков.

4. РЕЗУЛЬТАТЫ

Результаты для первого слоя представлены на рис. 2. Для второго и третьего слоев наблюдается аналогичная картина.

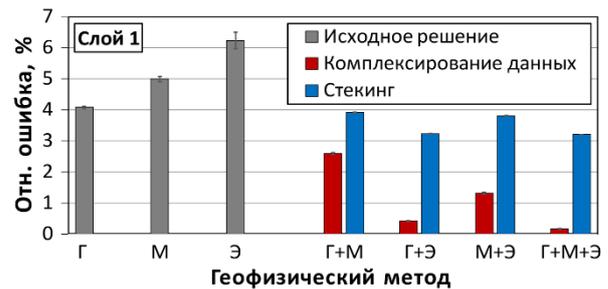


Рис. 2. Результаты решения ОЗ РГ для различных способов комплексирования данных. Г, М, Э – индивидуальное использование данных гравиметрии, магнитометрии и электроразведки; Г+М, Г+Э, М+Э, Г+М+Э – одновременное использование данных нескольких геофизических методов

5. ВЫВОДЫ

По результатам работы можно сделать следующие выводы:

- Комплексирование данных нескольких геофизических методов улучшает качество решения по сравнению с индивидуальным использованием каждого из них.

- Наилучшее качество решения наблюдается при одновременном использовании данных всех трех геофизических методов.

- Данный эффект наблюдается для всех слоев, а также для каждого из рассматриваемых подходов к комплексированию данных.

- Качество решения при непосредственном обучении нейронных сетей на данных сразу нескольких геофизических методов оказалось выше, чем при использовании подхода, основанного на стекинге, где каждая нейронная сеть, входящая в комитет, обучалась на данных только одного геофизического метода.

БЛАГОДАРНОСТИ

Исследование выполнено за счёт гранта Российского Научного фонда, проект № 19-11-00333.

ЛИТЕРАТУРА

[1] Isaev, I. Neural Network Solution of Inverse Problems of Geological Prospecting with Discrete Output / I. Isaev, I. Osbornev, E. Osbornev, E. Rodionov, M. Shimelevich, S. Dolenko // Proc. of Science. – 2021. – Vol. 410. DOI: 10.22323/1.410.0003.