



Статья посвящена описанию новой технологии прогнозирования каротажных данных в объеме в межскважинном пространстве на примере коэффициента пористости при помощи искусственных нейронных сетей. В статье изложена постановка задачи и подробно описаны этапы технологии, такие как подготовка обучающей выборки, выбор архитектуры сети, обучение нейронной сети и расчет прогнозного куба.

Применение нейросетей для прогнозирования пористости в 3D кубах (расчет по сейсмическим атрибутам и каротажным данным)

Лаврик А.С., Логинов Д.В., Ванярхо М.А., ОАО «ЦГЭ», г. Москва

Введение

В данной статье мы приводим описание нового подхода к прогнозированию пористости в кубах 3D на основе нейронных сетей. Прогнозирование фильтрационно-емкостных свойств (ФЕС) среды в межскважинном 3D объеме является одной из интенсивно развивающихся областей разведочной геофизики нефти и газа. Априорные модели, построенные в предположении о возможном виде связей между свойствами сейсмических полей, геофизическими исследованиями скважин (ГИС) и ФЕС (или свойствами пород, их петрофизическими характеристиками), пытаются явно выразить эти связи в аналитическом виде и использовать полученные теоретические результаты для прогнозирования с помощью подбора параметров моделей. Однако, сложность физических явлений, лежащих в основе подобных закономерностей, нелинейный характер взаимодействия среды с сейсмическими полями, осложняющийся уникальными условиями залегания, далеко не всегда позволяют получить удовлетворительную модель для прямого прогнозирования ФЕС. В этом случае большое значение приобретает альтернативный подход, заключающийся в том, что данные сейсмические S и измерений ГИС G , играющие второстепенную роль при построении априорных моделей, выступают на первое место и при помощи некоторого настраиваемого (при помощи параметров P) механизма нелинейного отображения $F(S \rightarrow G; P)$, позволяют получить неявную модель среды, основанную непосредственно на данных измерений [1-8]. Таким образом, появляется возможность, минуя промежуточные шаги, получать результат прогнозирования напрямую, при помощи найденной аппроксимации нелинейного отображения F . В частности, подобный нелинейный механизм представляют искусственные нейронные сети (ANN), которые

и использовались в нашей работе.

Этапы построения прогнозного куба 3D

На Рис.1 представлены основные этапы построения прогнозного куба 3D. На 1-м этапе производится подготовка обучающей выборки для обучения прогнозирующей нейронной сети. Далее (Этап 2) производится выбор архитектуры нейронной сети. В наших исследованиях использовалась специально разработанная нейронная сеть на основе многослойного линейного перцептрона с модифицированным алгоритмом обучения Левенберга-Марквардта [9, 10, 11] и начальной инициализацией сети с помощью метода Нгуена-Видроу [12]. Выбор архитектуры (количество слоев и нейронов) производился при помощи специальной разработанной процедуры автоматического выбора оптимальной конфигурации сети. На 3-м этапе производится обучение сети с выбранной конфигурацией на полученной ранее обучающей выборке. И, наконец, на 4-м этапе с помощью обученной нейронной сети производится расчет прогнозного 3D куба.




Рис.2 Подготовка обучающей выборки

Подготовка обучающей выборки. Исходные данные

Для создания обучающей выборки необходимы следующие данные:

- сейсмический куб во временном пространстве (до перевода в глубины);
- рассчитанный по кубу набор сейсмических атрибутов;
- данные о траекториях скважин;
- скоростные законы на скважинах;
- данные коэффициента пористости вдоль стволов скважин.

Можно было бы предложить другую комбинацию исходных

1. Подготовка обучающей выборки

2. Выбор архитектуры нейронной сети

3. Обучение нейронной сети

4. Расчет прогнозного куба 3D

Рис.1 Этапы построения прогнозного куба 3D

данных, в которой сейсмический куб пересчитан в глубину. В этом случае все вычисления проводились бы в едином «геологическом» пространстве, однако такой вариант менее предпочтителен, поскольку при пересчёте в глубину могут вноситься искажения в форму сейсмического сигнала. Далее в тексте мы будем считать, что используется первый набор исходных данных.

Обучающая выборка – это таблица $A_i, \dots, A_N \rightarrow \varphi, i=1, \dots, M$, где $A_j, j=1, \dots, N$ – сейсмические атрибуты, от которых может зависеть коэффициент пористости φ , M – объем выборки, φ – количество сейсмических атрибутов. Обучающая выборка подается на вход нейронной сети для её обучения.

Перевод глубина-время каротажных кривых при помощи скоростных законов

Ключевым моментом при подготовке исходных данных является нахождение скоростного закона в каждой скважине. Точность привязки глубинных отметок к соответствующим осям синфазности в сейсмическом кубе является критическим параметром для решения всей задачи.

В результате того, что при помощи скоростного закона сейсмические и каротажные данные располагаются в одном пространстве, появляется возможность каждому значению коэффициента пористости сопоставить набор значений сейсмических атрибутов, измеренных в этой точке пространства.

На этом этапе возникают две проблемы: первая – разрешение скважинных данных на порядок превышает разрешение сейсмических измерений; вторая – траектория ствола скважины, как правило, не попадает в узлы решётки сейсмических 3D данных.

Первая проблема является достаточно сложной. Если для создания обучающей выборки использовать дискретизацию каротажных измерений, то можно получить противоречивую выборку, поскольку одним и тем же значениям сейсмических атрибутов могут соответствовать различные значения коэффициента пористости. Напротив, если за основу мы возьмём дискретизацию сейсмических измерений, то обучающая выборка превратится в белый шум.

Низкочастотная фильтрация каротажной кривой

Мы предлагаем привести скважинные данные (коэффициент пористости) к такому частотному составу, при котором мы могли бы сопоставить эти измерения с сейсмическими данными. Иными словами, при помощи преобразования Фурье мы убираем из кривой пористости высокие частоты, ограничивая спектр. Таким образом, применяется низкочастотный фильтр, оставляющий в сигнале колебания, период которых больше заданного




Рис.3. Исходная (зеленый) и отфильтрованная (чёрный) каротажные кривые




Рис.4. Коэффициент пористости, заданный интервально, изображённый на фоне сейсмического куба во временной области

порога (например, двадцати метров). После этого, основываясь на теореме Котельникова-Шеннона, переходим к шагу дискретизации сейсмического сигнала (Рис.3). Такой способ приведения позволяет решить проблемы аляйсинга.

Приведение кривой пористости к разрешению сейсмических данных

Отметим, что фильтрация проводится до перевода каротажных данных во временную область. После перевода во временную область получается дискретно заданная функция пористости на неравномерной решётке. При проведении преобразований преследуются следующие цели:

- 1) получение пористости φ во временной области;
- 2) для фиксированного интервала времени количество дискретов, на которых определено значение пористости φ , примерно такое же, как и количество дискретов, которыми представлена сейсмическая трасса на том же интервале.

Задание соответствия набора сейсми-

ческих атрибутов $A_{11}, \dots, A_{1N}$ и пористости φ (в выделенной точке пространства ХУТ).

Далее каждому значению коэффициента пористости, отнесенного к конкретному месту пространства ХУТ, ставится в соответствие набор значений из сейсмического куба и кубов атрибутов, отнесенный к этой же точке пространства с помощью восьмиточечной линейной интерполяции. Линейную интерполяцию можно использовать, предполагая, что в пределах дискретизации сейсмические атрибуты ведут себя линейно.

При описанном подходе мы, естественно, теряем детальность представления, свойственную скважинным данным, но на данном этапе развития технологии такие потери являются удовлетворительными.

Описанная процедура создания обучающей выборки подходит для случая, когда прогнозируемая каротажная кривая задана непрерывно (с малым шагом дискретизации, например 20 см.). Однако на практике коэффициент пористости часто представлен в виде интервальной (ступенчатой) кривой, значения которой постоянны в пределах одного пласта. В случае, если длина интервала меньше характерной длины сейсмической волны, то точкой соответствия с

сейсмическими атрибутами можно выбрать начало интервала. Интервалы с постоянным значением пористости, длина которых больше, интервал можно разбить на несколько частей и, таким образом свести к предыдущему случаю.

Стандартизация кубов атрибутов обучающей выборки

Последним этапом подготовки обучающей выборки является процесс стандартизации. Для корректной работы нейронной сети необходимо произвести статистическую стандартизацию входов этой сети, то есть провести преобразование $A_s = \frac{A - \bar{A}}{S}$ для каждого

«образца для обучения» (A_s — стандартизованное значение входной переменной A , $\bar{A}$ — среднее значение входной переменной, S — стандартное отклонение). Однако вычислять среднее и стандартное отклонение следует не только по обучающей выборке, а по всему объему кубов атрибутов, так как значения в обучающей выборке представляют собой лишь малое подмножество всего пространства прогнозируемого значения. Для согласования с обучающей выборкой процесс стандартизации необходимо провести для каждого куба атрибута.

Выбор архитектуры нейронной сети

Архитектура нейронной сети определяется следующими факторами:

- выбор типа сети;
- выбор алгоритма обучения;
- выбор способа начальной инициализации;
- выбор активационных функций;
- выбор количества скрытых слоев (для сетей, допускающих несколько слоев);
- выбор количества нейронов на каждом скрытом слое.

В нашем случае была выбрана сеть типа многослойный линейный перцептрон (MLP) [9,13]. Сеть MLP является универсальным аппроксиматором для широкого класса функций. Для обучения сети использовался модифицированный метод обучения — алгоритм Левенберга-Марквардта [9,10,11]. Этот метод обеспечивает лучшую сходимость и существенно быстрее обычных методов градиентного спуска. Начальная инициализация определяет начальное распределение весов сети и при удачном выборе обеспечивает быструю сходимость. В нашей работе был использован метод Нгуена-Видроу [12], позволяющий работать в почти линейной, ненасыщенной области функций активации, что обеспечивает лучшую сходимость и устойчивость работы алгоритма. Активационной функцией был выбран гиперболический тангенс

$$th(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}},$$




Рис 5. Коэффициент корреляции между прогнозом пористости и истинным значением (0.75)




Рис 6. Общий вид прогнозного куба пористости



который является симметричной функцией с достаточно широкой областью линейности [13]. Для исследования и выбора оптимальной структуры нейронной сети был использован специально разработанный алгоритм быстрого выбора с полным перебором скрытых слоев и нейронных количеств на каждом слое. Для обработки материалов, используемых на практике, оказалось достаточным использование двух слоев с количеством нейронов 17 и 3 или одного слоя с 20 нейронами.

Обучение нейронной сети

Критерием обучения сети служит суммарная квадратичная ошибка $\varepsilon = \sum_{i=1}^M (\phi_{\text{ист}}^i - \phi_{\text{прог}}^i)^2$, полу-

чаемая между выходом нейронной сети (прогнозом пористости) и истинным значением пористости на обучающей выборке. Целью обучения является минимизация среднеквадратической ошибки при сохранении обобщающих, прогностических возможностей сети.

На рис.5 приведен полученный кросс-плот прогнозного значения пористости, рассчитанного по нейронной сети и истинных значений пористости по обучающей выборке. При этом очевидно хорошее согласование значений при коэффициенте корреляции равном 0.75.

Расчет прогнозного куба 3D

В результате получения обученной нейронной сети (иными словами после построения на ее основе аппроксимации отображения $F(S \rightarrow G; P)$), становится возможным рассчитать прогнозные кубы пористости (рис.6).

Далее, для всех точек пространства ХУТ, в которых определен сейсмический куб и его атрибуты, получаем значения аппроксимируемой функции F. Поочередно на вход нейронной сети, реализующей отображение F, подаются значения сейсмических атрибутов из каждой точки пространства и в результате получается расчетное значение пористости в данной точке.

Примеры применения

Описанный выше подход прогнозирования пористости в 3D кубах был реализован в виде производственной технологии, разработанной в ОАО «ЦГЭ» и успешно примененной при работе на площадях: Восточно-Ингинская, Пальяновская, Узень, Восточный Уренгой, Северо-Истокская и др.

Технология представляет собой комплекс из двух программных продуктов, также разработанных в ОАО «ЦГЭ». Это интерпретационный комплекс DvSeisGeo [14], в котором в рамках данной технологии осуществлялся расчет сейсмических атрибутов, подготовка обучающей выборки и анализ результатов, а также программа SeisProN [15], в которой был проведен выбор архитектуры нейронной сети, обучение нейронной сети и расчет прогнозного куба пористости. Куб пористости представлен в стандартном формате SegY.

Выводы

В приведенной работе описаны этапы производственной технологии, позволяющей получать кубы пористости на основе совмещения данных сейсморазведки, ГИС и нейронных сетей. Данная технология впервые позволяет получать данные прогноза напрямую – на основе моделирования свойств среды при помощи нейронной сети, как механизма нахождения и отображения нелинейных связей между сейсмическими атрибутами и прогнозным параметром (ФЕС) (пористостью). При соответ-

ствующем выборе сейсмических атрибутов, обучающей выборки и скважинных данных данная технология легко расширяется до прогнозирования произвольных прогнозных параметров, для которых существует зависимость от сейсмических данных. Авторами планируется объединение технологии в рамках единой программы, позволяющей визуализировать данные и составлять произвольные выборки для обучения нейронных сетей и прогнозирования. Практический опыт применения технологии заслужил высокую оценку производственных подразделений и показал своевременность выполненных исследований и разработок, воплощенных в новую технологию.

Литература

1. Daniel P Hampson, James S Shueke, and John A Quirein, 2001, Use of multiattribute transforms to predict log properties from seismic data: Geophysics, Vol.66, No.1, pp.220-236.
2. Rafael E.Banchs and Reinaldo J.Michelena, 2002, From 3D seismic attributes to pseudo-well-log volumes using neural networks: Practical considerations: The Leading Edge 21, 996.
3. Zhengping Liu and Jiaqi Liu, 1998, Seismic-controlled nonlinear extrapolation of well parameters using neural networks: Geophysics, Vol.63, No.6, pp.2035-2041.
4. Rafael E.Banchs and Reinaldo J.Michelena, 2000, Well log estimates and confidence intervals by using artificial neural networks: SEG Technical Program Expanded Abstracts, pp.1430-1432.
5. Philip S.Shultz, Shuki Ronen, Masami Hattori and Chip Corbett, 1994, Seismic-guided estimation of log properties (Part 1: A data-driven interpretation methodology), The Leading Edge 13, 305.
6. Philip S.Shultz, Shuki Ronen, Masami Hattori and Chip Corbett, 1994, Seismic-guided estimation of log properties (Part 2: Using artificial networks for nonlinear attribute calibration), The Leading Edge 13, 674.
7. Philip S.Shultz, Shuki Ronen, Masami Hattori, Pascal Mantran and Chip Corbett, 1994, Seismic-guided estimation of log properties (Part 3: A controlled study), The Leading Edge 13, 770.
8. M. Turhan Taner, 2001, Seismic Attributes: Rock Solid Images, Houston, U.S.A. CSEG Recorder, September 2001.
9. Осовский С., 2004, Нейронные сети для обработки информации / пер. И.Д.Рудинского. - М.: Финансы и статистика.
10. Fletcher R., 1980, Practical methods of optimization. Vol. 1: Unconstrained Optimization. Department of Mathematics: University of Dundee, Scotland, U.K.
11. Manolis I., A. Lourakis, 2005, A brief description of the Levenberg-Marquardt algorithm implemented. Institute of computer science foundation for research and technology, Heraklion, Crete, Greece.
12. Nguyen D., and Widrow B., 1990, Neural Networks, 1990 IJCNN International Joint Conference on Volume, Issue, 17-21 Jun 1990 Page(s):21 - 26 vol.3.
13. Тархов Д.А., 2005, Нейронные сети. Модели и алгоритмы, "Радиотехника", Москва.
14. Комплекс DvSeisGeo, 2007, Федоров А.Л., Ческис В.Л., Ческис О.А., Казаров А.С., Ванярхо М.А., ОАО «ЦГЭ»
15. Программа SeisProN, 2006, Кашик А.С., Логинов Д.В., Лаврик С.А., Белянушкина М.С., Ванярхо М.А., ОАО «ЦГЭ»