

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ. ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Александр Владимирович КУГАЕВСКИХ¹

УДК 004.94

ПРОГНОЗИРОВАНИЕ НЕКОТОРЫХ ПАРАМЕТРОВ ГАЗОКОНДЕНСАТНЫХ СКВАЖИН С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

¹ кандидат технических наук, доцент
кафедры медицинской и биологической физики,
Тюменский государственный медицинский университет
a-kugaevskikh@yandex.ru

Аннотация

В современных условиях точные измерения выхода на газоконденсатных скважинах затруднены и, как следствие, затруднено прогнозирование. Обычно измеряют параметры на участках сбора, но при этом нельзя получить четкую картину по каждой конкретной скважине. Тем не менее, на основании истории измерений некоторых параметров скважины можно предсказать ее выходные параметры. При этом необходимо учитывать взаимное влияние этих параметров и историю их изменения.

Исследование, описанное в настоящей работе, направлено на получение механизма прогнозирования расхода газоконденсатной смеси и КГФ с ошибкой прогнозирования не

Цитирование: Кугаевских А. В. Прогнозирование некоторых параметров газоконденсатных скважин с помощью нейронных сетей / А. В. Кугаевских // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2017. Том 3. № 1. С. 91-98.

DOI: 10.21684/2411-7978-2017-3-1-91-98

более чем в 5%. В работе представлено практическое применение обобщенно-регрессионной нейронной сети к задаче прогнозирования некоторых параметров скважин. Дано обоснование использования именно этой топологии. Проведенная экспериментальная проверка показала приемлемое качество функционирования предлагаемого алгоритма. Приведена зависимость ошибки прогнозирования от количества точек обучения. Исходя из экспериментальных данных, применение сети GRNN для прогнозирования дебита газа и КГФ видится перспективным.

Тем не менее, применение нейронной сети не учитывает физики явления, что также отрицательно сказывается на точности предсказания выбранных параметров.

Ключевые слова

Нейронные сети, прогнозирование, конденсатно-газовый фактор.

DOI: 10.21684/2411-7978-2017-3-1-91-98

Введение

Одной из областей применения нейросетевого прогнозирования является нефтегазовая сфера. Причем здесь неприменимо большинство топологий нейронных сетей. Во-первых, многие из них выявляют только зависимость выходных результатов от времени (такие топологии больше применимы для выявления закона изменения величины и формирования тренда). Во-вторых, в нефтегазовой сфере осталось мало задач, которые бы не были решены с помощью более точных физико-технических методов. Одной из таких задач может быть прогнозирование расхода газоконденсатной смеси и конденсатно-газового фактора.

Описание задачи

При прогнозировании расхода газоконденсатной смеси и конденсатно-газового фактора зависимость этих параметров от времени крайне слабо выражена. В данном случае ярко выражена зависимость от состояния среды и управляющих параметров. Целью данного исследования является получение механизма прогнозирования с ошибкой прогноза в 5%.

Входные и выходные параметры описываются следующими векторами:

X — вектор параметров на входе. Включает 7 компонентов:

1. $P_{сб}$, Н/м² — давление газоконденсатной смеси на узле сбора.
2. $P_{ум1}$, Н/м² — давление смеси перед штуцером.
3. $P_{ум2}$, Н/м² — давление смеси после штуцера.
4. $T_{ум}$, К — температура на устье.
5. P_3 , Н/м² — давление на забое.
6. $P_{пл}$, Н/м² — давление в пласте (постоянно для серии).
7. $d_{ум}$, мм — диаметр штуцера.

Y — вектор параметров на выходе. Включает 2 компонента:

1. G , кг/с — расход газоконденсатной смеси.
2. КГФ — конденсатно-газовый фактор.

Таблица 1

Сравнение качества прогнозирования

Срок прогнозирования	MLP	Elman	Fahlman	GRNN
до 3 месяцев	6%	5,6%	5%	4,8%
до 6 месяцев	17%	16,3%	14,7%	14%

Table 1

Comparison of prognostication quality

Такой набор параметров и особенности их взаимовлияния на выходной результат накладывают ограничения на применяемые топологии нейросетей: многослойный персептрон [4], сеть Эльмана [2], сеть каскадной корреляции Фальмана [3], обобщенно-регрессионная сеть GRNN [5].

Описание модели решения задачи

Над отобранными нейронными сетями были проведены эксперименты на тестовых данных по одной из скважин. При этом диаметр штуцера и разность давлений были взяты постоянными и равнялись значениям на последний период из обучающего множества.

Оценка погрешности предсказания отображена в таблице 1.

Как видно из таблицы 1 наиболее точной для данной задачи является обобщенно-регрессионная нейронная сеть GRNN.

На вход сети поступают 7 параметров $X = (P_{сб}, P_{ум1}, P_{ум2}, T_{ум}, P_3, P_{пл}, d_{ум})$. Первый скрытый слой, функционирующий по принципу радиально-базисных функций, содержит все запомненные сетью точки измерений. Второй слой, функционирующий по принципу стандартного персептрона, вычисляет внутри-

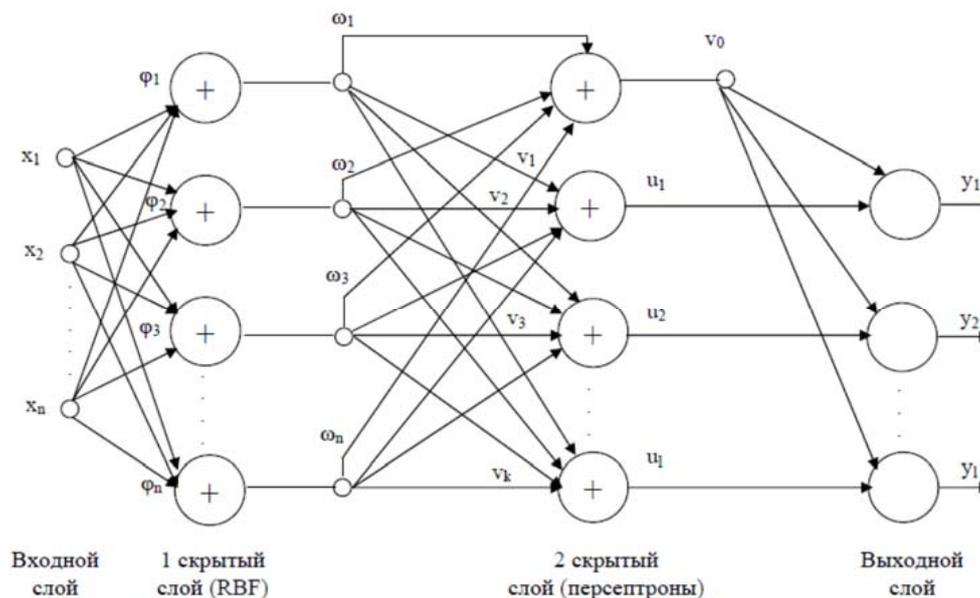


Рис. 1. Структура сети GRNN

Fig. 1. The GRNN network structure

системные значения для предсказания выходных параметров. Выходной слой на основании данных предыдущего слоя вычисляет предполагаемые значения дебита газа G и $КГФ К$.

В выходном слое определяется взвешенное среднее путем деления взвешенной суммы на сумму весов. В качестве радиальной функции применяется функция Гаусса.

Нейроны первого слоя функционируют по принципу радиально-базисной функции и вычисляются по формуле:

$$v_i = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{D_i}{2\sigma^2}\right),$$

где σ — определяет масштаб изменения радиально-базисной функции ($= 0.5$), D_i — Евклидово расстояние между вектором X и центром текущего кластера φ_i .

Евклидово расстояние отвечает за распознавание входного набора параметров, позволяя сети отличать один набор от другого и выявляя необходимые взаимозависимости. Рассчитывается по формуле:

$$D_i = (X - \varphi_i)^T (X - \varphi_i).$$

Параметр φ_i подбирается в результате обучения.

Выходной сигнал l -го нейрона второго промежуточного слоя вычисляется по формуле:

$$u_l = \sum_{i=1}^k v_i \omega_i,$$

где ω_i — веса нейрона, подбираемые в результате обучения.

Количество нейронов второго слоя равно количеству выходных параметров сети.

Выход сети вычисляется по формуле:

$$y_l = \frac{u_l}{\sum_{i=1}^k \omega_i}.$$

Центроиды функций нейронов первого слоя подбираются с помощью алгоритма *k-means++* [1]. На этом этапе алгоритма проводится в 10 итераций. Нейроны второго слоя обучаются по алгоритму обратного распространения ошибки [4]. Алгоритм обратного распространения ошибки сходится за 350 эпох, при этом энергия ошибки $E(n)$ становится равна 0,001.

Экспериментальная проверка

Для проверки функционирования были взяты данные по нескольким скважинам (приведены в таблице 2). Количество точек измерения 16. 30% точек из всего многообразия данных были случайно выбраны в качестве тестового множества, на остальных сеть обучалась (отделены жирной линией).

Средняя погрешность предсказания сетью по обоим выходным параметрам на таких данных составила 5% при 7 входных параметрах и 7% — при 4 входных параметрах. При этом наблюдаются редкие всплески погрешности (до 30%) из-за несогласованности данных.

Таблица 2

Данные замеров по скважинах

Table 2

The wells measurements data

№	$d_{ум}$	P_3	$P_{ум1}$	$P_{ум2}$	$P_{сб}$	$T_{ум}$	$P_{пл}$	G	КГФ
1	7,94	440,5	323,1000	108,8864	98,1002	105,42	567	4,2324	385,4159
2	9,53	388,7	272,6923	89,6528	98,3962	105,32	567	4,7145	295,5029
3	12,70	308,8	202,1538	97,8770	97,9028	105,22	567	5,7279	255,6811
4	14,29	270,5	165,8462	79,9527	97,6067	105,12	567	5,7753	233,9604
5	15,88	239,3	138,8667	80,7329	99,4819	105,02	567	5,7649	223,1095
6	14,29	251,3	149,8889	73,3066	95,7316	100,21	567	5,2509	199,6276
7	11,11	296,8	191,4118	76,5721	96,7185	102,38	567	4,2486	245,6834
8	7,94	458,6	337,1081	91,0455	88,4283	105,60	554	3,7244	294,5873
9	9,53	452,8	325,8421	97,7880	84,3819	105,49	554	5,1702	282,2444
10	12,70	437,3	299,5556	103,1081	92,5734	105,47	554	8,4005	280,5615
11	14,29	426,2	280,3333	107,0626	91,0930	105,42	554	9,6369	292,2407
12	15,87	414,0	256,2105	109,7845	86,5532	105,36	554	10,9312	284,0841
13	14,29	414,8	271,4737	108,6332	95,0407	105,35	554	9,3276	289,1835
14	11,11	424,5	297,6774	100,1263	87,0466	105,37	554	6,4183	287,5175
15	9,53	403,4	298,5714	111,3819	87,6388	104,42	549	4,5876	254,8390
16	11,11	399,2	285,6500	121,6829	86,2571	104,42	549	5,8332	243,2350
Погрешность, %								4,0	5,8

При использовании данных по скважинам с меньшим количеством точек погрешность немного возрастает. При 6 и более точках обучения погрешность предсказания находится в пределах 5-7%. При 5 и менее точках обучения погрешность увеличивается и в итоге превышает 10%. Для 3 точек она составляет 18%.

Заключение

Исходя из экспериментальных данных, применение обобщенной регрессионной нейросети для прогнозирования дебита газа и КГФ видится перспективным. С увеличением числа точек измерения, запоминаемых сетью, погрешность будет снижаться, но не станет меньше 4% на реальных данных, что объясняется погрешностью метода прогнозирования.

Несмотря на то, что требованию по ошибке прогноза в 5% удовлетворяют две сети: сеть Фальмана и GRNN — сеть GRNN показывает более качественные результаты.

Высокая погрешность предсказания, наблюдаемая в редких случаях, появляется из-за несогласованности данных. Соответственно, для снижения ошибки работы сети, необходим более тщательный подбор входных данных.

СПИСОК ЛИТЕРАТУРЫ

1. Arthur D. k-means++: the advantages of careful seeding / D. Arthur, S. Vassilvitskii // Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms. Society for Industrial and Applied Mathematics Philadelphia. PA, USA, 2007. pp. 1027–1035.
2. Elman J. L. Finding Structure in Time / J. L. Elman // Cognitive Science. 1990. Pp. 179-211. DOI: 10.1016/0364-0213(90)90002-E
3. Fahlman S. E. The Cascade-Correlation Learning Architecture / S. E. Fahlman, C. Lebiere // Advances in Neural Information Processing Systems 2 (NIPS 1989). 1989. Pp. 524-532.
4. Rummelhart D. E. Learning Representations by Backpropagation Errors / D. E. Rummelhart, G. E. Hinton, R. J. Williams // Nature 323. 1986. Pp. 533-536. DOI: 10.1038/323533a0
5. Specht D. F. A General Regression Neural Network / D. F. Specht // IEEE Transactions of neural networks. 1991. Vol. 2. No 6. Pp. 568-576. DOI: 10.1109/72.97934

Alexander V. KUGAEVSKIKH¹

**PREDICTION OF SOME PARAMETERS
OF GAS-CONDENSATE SLITS
BY MEANS OF NEURAL NETWORKS**

¹ Cand. Sci. (Tech.), Associate Professor,
Tyumen State Medical University
a-kugaevskikh@yandex.ru

Abstract

Under present-day conditions the accurate measurements of the yield on gas condensate wells are difficult and, as a consequence, prediction is difficult too. Typically, the parameters are measured in the collection areas, but you cannot get a clear picture for each specific well. Nevertheless, based on the history of changes in some parameters of the well, its output parameters can be predicted. In this case, it is necessary to take into account the mutual influence of these parameters and the history of their change.

The study described in this paper is aimed to obtain a mechanism for predicting the flow of a gas-condensate mixture and a gas-condensate ratio with a forecast error of no more than 5%. The practical application of the generalized regression neural network to the problem of prediction of some well parameters is presented. The rationale for using this topology is given. The conducted experimental check showed the acceptable quality of the proposed algorithm. The dependence of the prediction error on the number of learning points is given. Based on the experimental data, the application of GRNN network for forecasting the gas production rate and gas-condensate ratio is considered promising.

Nevertheless, the application of the neural network does not take into account the phenomenon physics, which also negatively affects the accuracy of the selected parameters prediction.

Keywords

Neural network, prediction, gas-condensate factor.

DOI: 10.21684/2411-7978-2017-3-1-91-98

Citation: Kugaevskikh A. V. 2017. "Prediction of Some Parameters of Gas-Condensate Slits by Means of Neural Networks". Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy, vol. 3, no 1, pp. 91-98.
DOI: 10.21684/2411-7978-2017-3-1-91-98

REFERENCES

1. Arthur D., Vassilvitskii S. 2007. "k-means++: the advantages of careful seeding". Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms. Society for Industrial and Applied Mathematics Philadelphia. PA, USA, pp. 1027-1035.
2. Elman J. L. 1990. "Finding Structure in Time". Cognitive Science, pp. 179-211. DOI: 10.1016/0364-0213(90)90002-E
3. Fahlman S. E., Lebiere C. 1989. "The Cascade-Correlation Learning Architecture". Advances in Neural Information Processing Systems 2 (NIPS 1989), pp. 524-532.
4. Rummelhart D. E., Hinton G. E., Williams R. J. 1986. "Learning Representations by Backpropagation Errors". Nature 323, pp. 533-536. DOI: 10.1038/323533a0
5. Specht D. F. 1991. "A General Regression Neural Network". IEEE Transactions of Neural Networks, vol. 2, no 6, pp. 568-576. DOI: 10.1109/72.97934