DOI: https://doi.org/10.25689/NP.2025.4.266-283
EDN TGVEVL
УДК 004.8:622.279.5

Прогнозирование обводнения газовых скважин при помощи моделей машинного обучения (ML-моделей)

[1, 2]Юшков А.Ю., [2]Лычагин Н.П., [2]Шумейко Р.Ю., [2]Огуречников Н.М., [2]Шумалкин В.С.

[1]ООО «Тюменский нефтяной научный центр», Тюмень, Россия

[2]ФГБОУ ВО «Тюменский индустриальный университет», Тюмень, Россия

Predicting of gas wells watercut using a machine learning models (ML-models)

[1, 2]A.Yu. Yushkov, [2]N.P. Lychagin, [2]R.Yu. Shumeiko, [2]N.M. Ogurechnikov, [2]V.S. Shumalkin

[1]Tyumen Petroleum Research Center LLC, Tyumen, Russia

[2]Tyumen Industrial University, Tyumen, Russia

E-mail: ayyushkov@tnnc.rosneft.ru

Аннотация. В статье рассматривается проблема адресного прогнозирования обводнения газовых скважин, ее актуальность, существующие решения. В качестве альтернативного метода прогнозирования авторы предлагают использовать инструменты машинного обучения (ML-модель). Для апробации подхода была сформирована обучающая выборка из синтетических данных, полученных по результатам гидродинамического моделирования разработки газовых залежей различной конфигурации, имеющих малую газонасыщенную толщину. В качестве входных параметров ML-модели приняты 13 заранее известных геологических и технологических факторов, характеризующих каждую скважину, выходными (прогнозными) параметрами модели являются: год начала обводнения скважины и динамика роста водогазового фактора. Проведён анализ эффективности различных алгоритмов машинного обучения, подробнее рассмотрена реализация алгоритма XGboost. По результатам тестирования модели на контрольной выборке получена хорошая точность прогноза времени начала обводнения скважин в схожих геологических условиях. Сделан вывод о том, что ML-модели способны решать частные задачи

управления разработкой, обеспечивая быстрый прогноз выборочных целевых параметров.

Ключевые слова: *разработка газовых месторождений, газовые скважины, гидродинамическое моделирование, прогноз обводнения, машинное обучение, нейронные сети*

Для цитирования: Юшков А.Ю., Лычагин Н.П., Шумейко Р.Ю., Огуречников Н.М., Шумалкин В.С. Прогнозирование обводнения газовых скважин при помощи моделей машинного обучения (ML-моделей) // Нефтяная провинция.-2025.-№4(44).-С. 266-283. - DOI https://doi.org/10.25689/NP.2025.4.266-283. - EDN TGVEVL

Abstract. The article discusses the problem of prediction accuracy of gas well watercut, its relevance, and existing solutions. As an alternative prediction method, the authors suggest using machine learning tools (ML model). The training case is based on synthetic data obtained from the results of hydrodynamic modeling of the development of gas deposits of various configurations with low gas saturated thickness. 13 previously known geological and technological factors characterizing each well are accepted as input parameters of the ML model. The output (forecast) parameters of the model are: the year of the beginning of well watercut and the growth dynamics of the well water-gas ratio. The effectiveness of various machine learning algorithms is analyzed, and the implementation of the XGBoost algorithm is considered in more detail. Based on the results of testing the model on a control sample, a good accuracy of forecasting the time of the beginning of well flooding was obtained. It is concluded that ML models are capable of solving specific development management tasks, providing a quick forecast of selected target parameters.

Key words: *gas field development, gas well, hydrodynamic modelling, watercut prediction, machine learning, neural networks*

For citation: A.Yu. Yushkov, N.P. Lychagin, R.Yu. Shumeiko, N.M. Ogurechnikov, V.S. Shumalkin Prognozirovaniye obvodneniya gazovykh skvazhin pri pomoshchi modeley mashinnogo obucheniya (ML-modeley) [Predicting of gas wells watercut using a machine learning models (ML-models)]. Neftyanaya Provintsiya, No. 4(44), 2025. pp. 266-283. DOI https://doi.org/10.25689/NP.2025.4.266-283. EDN TGVEVL (in Russian)

Введение

В настоящее время значительное количество газовых месторождений вступили в позднюю стадию разработки, уровень газо-водяного контакта (ГВК) поднимается, а значит – риск обводнения скважин растет. Для своевременного принятия мер по борьбе с обводнением необходимо заблаговременно спрогнозировать момент начала поступления воды к забою.

Но на данный момент не существует надежных способов адресного прогноза обводнения газовых скважин. Из-за геологической неопределенности строения пласта точный прогноз на гидродинамической модели или аналитическим способом невозможен. Альтернативным методом прогнозирования и оценки рисков может стать машинное обучение.

Оценкой рисков обводнения газовых скважин занимались многие инженеры и коллективы. Например, А.И. Шаяхметов в своей работе рассматривал зависимость динамики обводнения от размеров зоны разбуривания, особенностей геологического строения [1]. В.Д. Усачев работал над гидродинамическим моделированием воздействия водонапорной системы на газовую залежь [2, 3]. Э.Р. Гасумов рассматривал зависимость уровня ГВК от пластового давления и объема отобранного газа [4]. С.В. Красноборов с группой выделяют несколько параметров, влияющих на обводнение, присваивают им вес и формируют формулу для расчета вероятности выбытия газовой скважины [5].

Недостаточная точность адресного прогноза обводнения газовых скважин на неразрабатываемых месторождениях может привести к неправильному выбору участков для бурения новых скважин. На разрабатываемых месторождениях могут иметь место следующие проблемы:

– Подбор недостаточно эффективного режима работы скважины.
– Неверное адресное планирование ремонта скважин.
– Незапланированная реализация компенсирующих мероприятий.

Основные газовые месторождения полярных регионов России можно разделить на три группы (Рис. 1)

Рис. 1. Разделение газовых месторождений на группы по толщине залежи

Для первой группы месторождений в силу большой газонасыщенной толщины залежей есть возможность применения всех существующих мер по борьбе с обводнением скважин. В частности, осуществляют ремонтно-изоляционные работы (РИР) с перфорацией вышележащего интервала и цементированием обводненного, поэтому риск потери скважины не велик. Для таких залежей точный адресный прогноз обводнения скважин не так актуален.

На второй группе месторождений недостаточно газонасыщенной толщины для РИР, поэтому здесь, в основном, применяют зарезки боковых стволов (ЗБС). Точный адресный прогноз обводнения таких скважин (а затем и боковых стволов) необходим для оценки запаса времени для возможной корректировки режима работы скважины и продления её безводной эксплуатации.

Для третьей группы месторождений с малой газонасыщенной толщиной (несколько метров), которые еще не разрабатываются, никакие методы по борьбе с обводнением не применимы. Необходимо пробурить скважины в таких местах, где они проработают дольше и рентабельнее. Поэтому на таких месторождениях очень важен точный прогноз обводнения. Быстро-

действующий инструмент для прогноза адресного обводнения скважин позволит оценить множество вариантов размещения скважин и выбрать наилучший.

На данный момент существует несколько способов прогнозирования обводнения газовых скважин:

– Гидродинамическое моделирование

– Аналитические модели

– Анализ истории добычи

В табл. 1 показано их сравнение с инструментами, использующими машинное обучение (ML-модели).

Таблица 1

Преимущества и недостатки существующих решений в сравнении с возможностями машинного обучения

	Анализ истории добычи	ГДМ	Аналитическая модель	Машинное обучение
Доступность	+	-	+	+
Простота использования	-	-	-	+/-
Подтверждаемость прогнозов	+	+/-	-	+
Время на подготовку и расчеты	-	-	+	+

План исследования

– Анализ и выбор параметров, влияющих на обводнение газовых скважин;

– Построение синтетических гидродинамических моделей газовых залежей различной конфигурации с перебором (изменением поочередно) выбранных параметров;

– Создание обучающей выборки на основе результатов гидродинамического моделирования;

– Создание и обучение ML-модели;

– Ретроспективный тест (апробация на синтетических данных).

Параметры, влияющие на скорость обводнения скважин

Опыт разработки газовых залежей и их гидродинамическое моделирование показывают, что время безводной работы добывающих скважин предположительно зависит от нескольких достаточно простых параметров, которые можно описать численными значениями (Рис. 2).

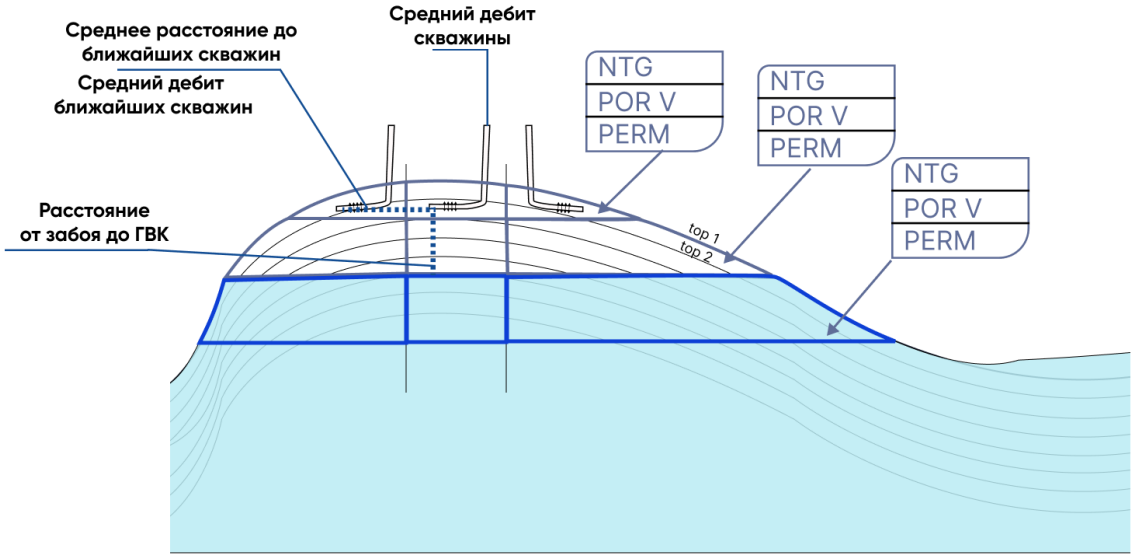

Рис. 2. Параметры, предположительно влияющие на время безводной работы скважин

1. *Средняя проницаемость блоков, относящихся к добывающей скважине [мД] (“PERM”, три блока на скважину)*. Так, например, низкая проницаемость среднего и нижнего блоков способствует более медленному движению воды к скважине.

2. *Средняя песчанистость блоков, относящихся к добывающей скважине [д.ед.] (“NTG”, три блока на скважину)*. Так, например, низкая песчанистость среднего блока также способствует более медленному движению воды к скважине из-за наличия в нём большего числа глинистых (непроницаемых) пропластков.

3. *Поровый объем блоков, относящихся к добывающей скважине [м^3] (“PORV”, три блока на скважину)*. Для верхнего блока данный параметр характеризует дренируемый объём газа и, соответственно, запас

высокого давления, препятствующего внедрению воды. Для среднего и нижнего блоков данный параметр характеризует объём и запас энергии внедряющейся воды. Соответственно, низкая величина порового объёма в этих блоках замедлит внедрение воды.

4. *Эффективная газонасыщенная толщина залежи [м]*. При условии вскрытия залежи горизонтальными скважинами с проводкой ствола под кровлей, данный параметр характеризует расстояние от забоя скважины до начального ГВК. Чем больше это расстояние, тем дольше скважина проработает без поступления воды.

5. *Средний дебит скважины [тыс.м^3/сут]*. Чем выше дебит скважины, тем выше темп истощения блока и выше темп внедрения воды в блок, дренируемый скважиной.

6. *Среднее расстояние до соседних скважин*. Чем ближе к скважине расположены соседние скважины, тем выше вероятность того, что в данном районе обводнение будет происходить более активно.

7. *Средний дебит соседних скважин [тыс.м^3/сут]*. Аналогично предыдущему параметру: чем выше дебиты соседних скважин, тем выше вероятность более активного обводнения.

Таким образом, имея набор синтетических гидродинамических моделей и различные варианты размещения скважин с прогнозом их обводнения, можно сформировать обучающую выборку для некоторой гиперфункции, в которой в качестве входных переменных будут использоваться вышеперечисленные параметры. На выходе гиперфункция должна выдавать (1) прогнозируемое (ожидаемое) время обводнения скважины и (2) ожидаемый характер обводнения в зависимости от значений входных переменных.

Создание синтетических гидродинамических моделей

С помощью ПО tNavigator были реализованы несколько вариантов моделей типичной сеноманской газовой залежи (глубина около 1000 м, прони-

цаемость 100-1000 мД) на основе кубов ФЕС, заданных массивом случайных чисел в Excel и структурных карт, построенных в Surfer (Рис. 3).

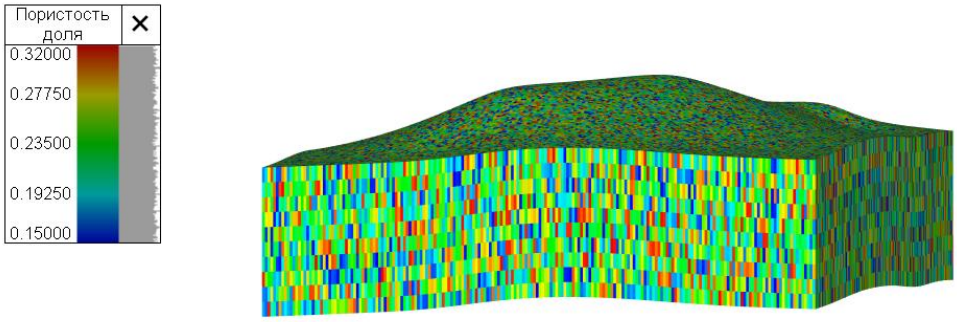

Рис. 3. Пример геологической модели пласта. Показано распределение пористости

Помимо латерального внедрения воды по напластованию, вода также поднимается «конусом» (вертикально), а значит нужно также учитывать влияние вертикальной проницаемости ячеек модели (PERMZ) на обводнение. Так как песчанистость зависит от количества проницаемых пропластков, располагающихся обычно горизонтально, справедливо будет полагать, что проницаемость ячеек по вертикали сильно зависит от песчанистости ячейки. Чтобы усилить эту связь, можно возвести NTG в степень. Поэтому проницаемость по оси Z предложено вычислить по формуле:

$$PERMZ = PERMX \times NTG^3, \quad (1)$$

где PERMX – проницаемость по оси X, мД;

NTG – песчанистость, д.ед.

Следует отметить, что такой подход косвенно усилил связь между входными параметрами (NTG, PERMX) и результатами расчета, которые существенно зависят от PERMZ.

С использованием перечисленных подходов были созданы синтетические гидродинамические модели восьми газовых залежей с различным (произвольным) геологическим строением и распределением фильтрационно-ёмкостных свойств (ФЕС). Для каждой геологической реализации были проведены прогнозные расчёты добычи газа с различным числом скважин, различными темпами отбора газа и расположением скважин.

Выгрузка данных из гидродинамических моделей

По результатам прогнозных расчётов на ГДМ были выгружены средние значения дебитов скважин за период их работы (до момента отключения), влияние соседних скважин (дебит и расстояние), динамика водогазового фактора (ВГФ). Далее с помощью MS Excel были извлечены: год прорыва воды в скважину, соответствующий первому ненулевому значению дебита воды, коэффициенты полинома степенной функции К1, К2(степень), описывающей характер роста ВГФ обводняющейся скважины во времени (Рис. 4):

$$Y = K_1 \times x^{K2}, \quad (2)$$

где Y – значение ВГФ, м^3/м^3;

x – время с начала обводнения скважины, годы.

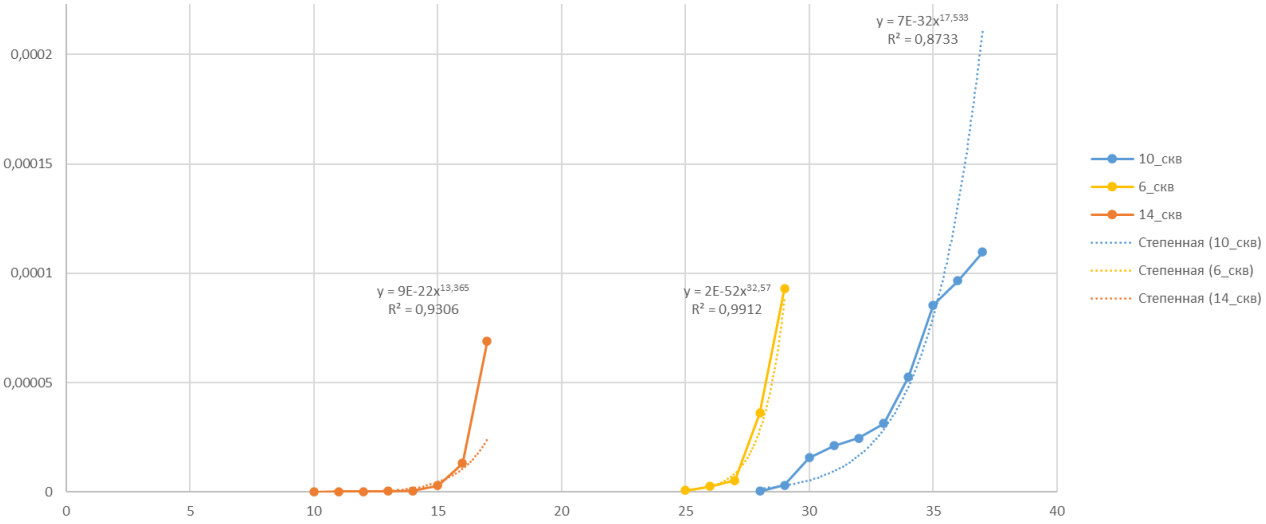

Рис. 4. Примеры роста ВГФ во времени

Средние значения литолого-фильтрационных параметров (PERM, PORO, NTG) по блокам каждой скважины были получены путём анализа цифровых 3D-кубов ФЕС с использованием цифровой карты зон, пример которой показан на рис. 5.

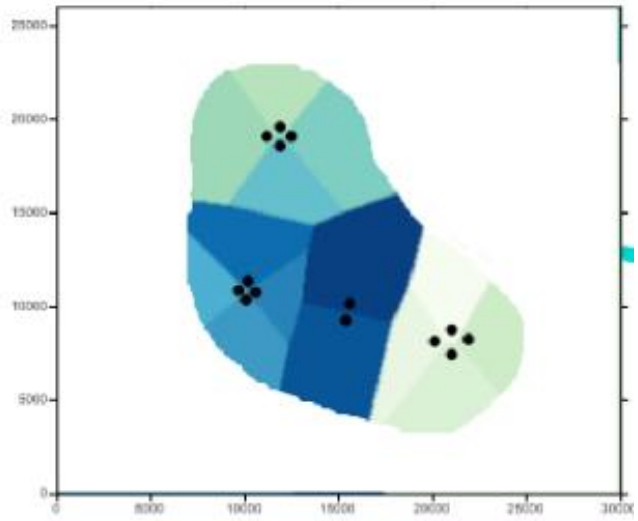

Рис. 5. Цифровая карта зон влияния скважин, ограничивающаяся внешним контуром газоводяного контакта

Обучающая выборка

По итогам моделирования был сформирован датасет из 1138 строк, содержащий 13 входных параметров и 3 целевых (выходных) значения (Табл. 2).

Таблица 2

Фрагмент датасета, на котором была обучена модель

№ записи (скв.)	Нэфф	Vпор1, млн	Vпор2, млн	Vпор3, млн	NTG1	NTG2	NTG3	PERM1	PERM2	PERM3	Qср	Lсосед, м	Qсосед	Год прорыва	Log. Коэф. К1	Степень
1	35,05	9,6	5,3	8,7	0,439	0,375	0,549	146,4	116,7	247,8	55000	1675,0	55000	35	-5,72	3,18
2	27,14	35,2	75,9	144,6	0,493	0,465	0,464	201,7	178,6	178,1	378000	4003,9	376555	14	-6,74	7,17
3	18,61	6,0	17,3	10,3	0,513	0,454	0,457	216,4	167,3	156,8	56000	1407,0	46583	7	-7,71	3,37
4	22,15	5,8	17,8	31,2	0,533	0,467	0,449	232,6	179,1	165,7	203000	2345,1	196793	7	-6,93	3,54
5	21,00	5,1	19,4	40,9	0,561	0,469	0,474	256,8	184,4	185,5	203000	2345,1	187729	13	-5,70	3,36
6	26,46	4,9	5,7	5,2	0,437	0,399	0,382	149,9	128,5	109,5	110000	1675,0	109093	11	-6,53	3,61
7	18,26	5,5	18,7	11,7	0,531	0,464	0,465	223,5	179,0	159,8	56000	1407,0	55745	5	-6,81	3,74
8	32,17	8,6	5,6	6,9	0,450	0,402	0,458	159,8	123,8	179,6	55000	1675,0	54484	26	-6,55	3,99
9	29,32	8,3	7,2	6,8	0,435	0,413	0,401	158,7	141,8	122,3	103000	2345,1	102379	27	-6,42	2,91
10	17,71	5,2	17,1	10,5	0,527	0,458	0,463	223,0	175,6	155,9	14666	1407,0	28000	8	-7,03	4,52
11	30,48	24,0	15,5	31,9	0,438	0,401	0,402	163,1	130,5	130,0	83000	2077,1	83000	22	-7,36	3,45
12	22,00	16,6	43,3	100,5	0,534	0,466	0,465	236,7	178,5	178,4	54849	2077,1	55000	16	-7,90	4,71
13	34,39	9,3	5,4	8,2	0,437	0,384	0,521	151,8	118,2	228,5	83000	1675,0	81618	23	-6,97	5,74
14	17,19	3,9	21,8	74,8	0,567	0,479	0,519	264,2	188,3	215,4	35340	1407,0	40309	6	-6,10	4,71
15	34,99	3,1	1,7	2,9	0,435	0,377	0,412	143,1	113,7	256,7	42000	1206,0	41984	14	-6,47	3,01
16	29,62	15,4	12,8	12,4	0,434	0,410	0,402	157,8	133,1	125,8	103000	3082,1	102739	35	-7,32	3,91
17	32,28	9,1	5,5	7,6	0,443	0,392	0,492	153,5	122,1	208,1	106408	1675,0	106569	9	-7,66	4,85
18	21,49	15,6	33,9	51,0	0,505	0,446	0,442	208,1	164,6	160,4	190000	4489,1	189864	21	-6,89	3,15
19	30,66	10,0	6,9	18,4	0,445	0,400	0,454	167,4	126,5	160,7	42000	1407,0	42000	28	-5,67	5,31
20	28,71	8,8	7,1	18,1	0,443	0,408	0,454	162,7	130,5	152,8	42000	1407,0	42000	22	-7,46	5,08

Анализ и выбор алгоритмов машинного обучения

Перед созданием ML-модели были проанализированы существующие решения и патенты по теме исследования, в которых был использован искусственный интеллект для решения задач в нефтегазовой отрасли. Был проведён анализ российских источников, а также рассмотрен международный опыт [6, 7]. В результате, для решения поставленной задачи были выделены следующие подходящие алгоритмы:

1. XGBoost – экстремальный градиентный бустинг;
2. CatBoost – градиентный спуск от Яндекса;
3. RNN – рекуррентная нейронная сеть;
4. LSTM – сети долгой краткосрочной памяти.

Решаемая проблема является нелинейной многовыходной регрессией. Для решения данной задачи хорошо подходят алгоритмы XGBoost и CatBoost [8]. Преимущества XGBoost относительно других моделей:

– Гибкий: позволяет работать с нелинейными зависимостями.
– Высокопроизводительный: алгоритм обрабатывает большие объемы данных и может работать с многими выходными переменными.
– Устойчивый: хорошо работает с пропущенными данными.

Реализация и обучение модели

Текущая версия XGBoost была обучена на 1138 записях датасета. Для реализации инструмента был использован язык программирования Python, онлайн и локальная среды для разработки: Google collaboration и Jupyter notebook, Библиотеки: Sklearn, Tensorflow, Numpy, Pandas.

Данные были разделены в пропорции 80 % на обучение и 20 % на тестирование. (911 записей – обучающая выборка, 227 – тестовая выборка). Реализацию модели можно разбить на 4 этапа:

1. Импорт всех необходимых библиотек, загрузка датасета, разделение данных на обучающую и тестовую выборку.
2. Обучение модели для прогнозирования года прорыва воды, К1, К2.

3. Вывод результатов обучения трёх целевых параметров (год, К1, К2) для тестовой выборки и сравнение результатов с реальными значениями.
4. Вывод важности каждого входного признака (параметра) из 13 для итогового предсказания каждого целевого выходного параметра.

Результаты обучения и качество прогноза

Для правильной интерпретации и оценки точности результатов моделей использованы следующие метрики:

MSE (Mean Squared Error, среднеквадратическая ошибка) – метрика, измеряющая среднюю квадратичную разницу между предсказанными значениями и реальными значениями.

MAPE (Mean Absolute Percentage Error) – метрика, измеряющая среднюю процентную ошибку между предсказанными значениями и реальными значениями. Соответственно, чтобы оценить точность модели из 100% вычитается значение MAPE. Точность прогноза по контрольной выборке составила:

– Год прорыва воды: MSE: 4.66, MAPE: 8.9%, Точ: 91,1 %.

– Логарифм коэффициента К1: MSE: 0.44, MAPE: 7.73%, Точ: 92,27 %

– Коэффициент К2(степень): MSE: 1.8, MAPE: 26.59%, Точ: 73,41%

Результаты модели для всех выходных параметров обладают высокой точностью (Табл. 3).

Таблица 3

Сопоставление результатов прогноза модели с реальными значениями в тестовой выборке

№ скв.	Год прорыва (реал.)	Год прорыва (пред.)	Log. Коэф. K1 (реал.)	Log. Коэф. K1 (пред.)	Степень (реал.)	Степень. K2 (пред.)
912	24	24,04	-8,475	-7,718	3,666	3,436
913	31	31,87	-6,706	-7,261	4,318	4,746
914	16	16,43	-7,305	-7,175	5,030	4,150
915	16	15,57	-5,979	-6,655	2,248	4,094
916	14	14,18	-6,766	-6,328	4,325	4,710
917	18	18,82	-6,426	-5,994	5,854	3,956
918	14	13,81	-6,278	-6,648	2,439	5,403
919	8	9,33	-7,036	-6,770	4,625	4,805
920	14	17,38	-8,554	-8,040	3,771	3,902
921	20	20,39	-7,488	-6,994	4,706	3,872
922	22	23,37	-5,911	-6,513	3,043	4,762
923	21	22,68	-6,444	-6,639	3,859	4,276
924	21	20,84	-6,768	-7,152	3,993	4,091
925	25	25,91	-7,747	-7,014	4,554	4,428
926	19	19,78	-7,222	-7,055	3,296	4,111
927	30	27,09	-6,266	-6,612	2,910	3,649
928	28	27,89	-6,931	-7,809	3,716	4,413
929	12	13,99	-8,184	-7,537	4,754	3,866
930	7	8,05	-6,567	-6,744	3,560	4,989
931	43	42,12	-7,521	-7,581	3,798	4,101

Рассмотрим также влияние каждого признака (входной переменной) на качество прогноза целевых переменных. Как видно из рис. 6, одним из важных факторов, влияющих на скорость обводнения газовых скважин, является «кучность» их размещения.

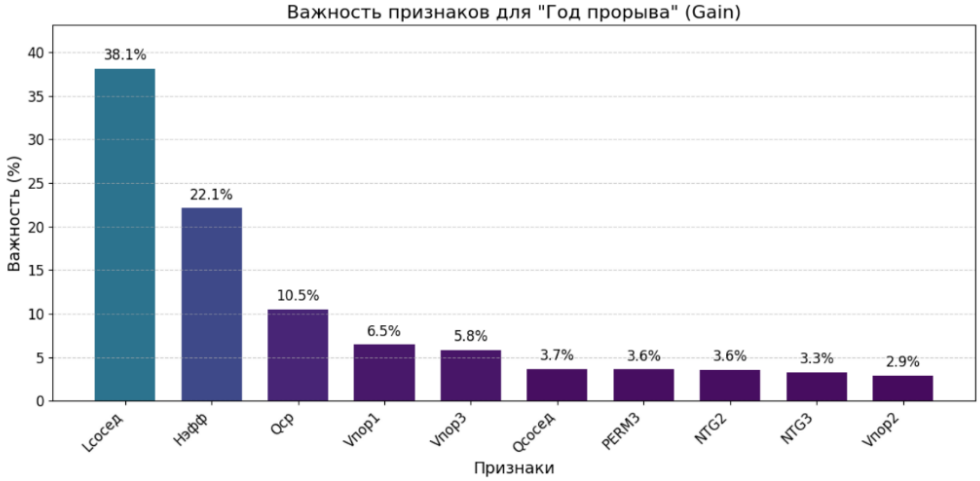

Рис. 6. Степень влияния входных параметров на прогноз года начала поступления воды в скважину

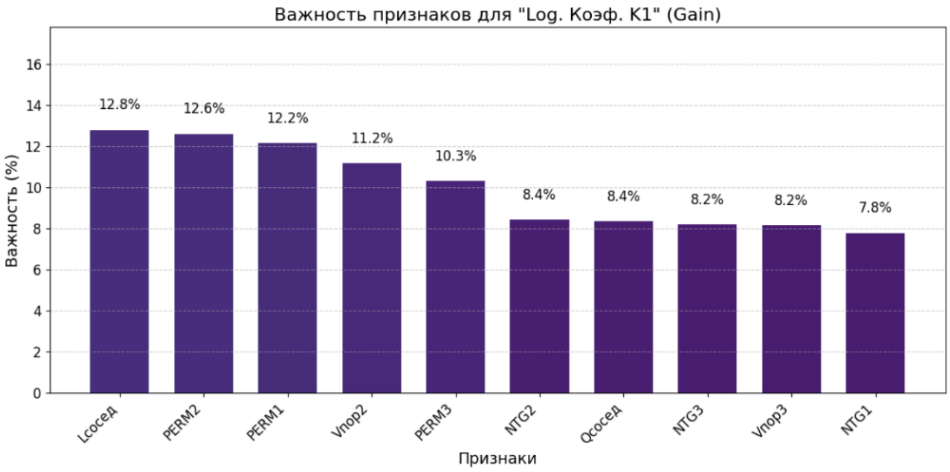

Рис. 7. Степень влияния входных параметров на прогноз логарифма коэффициента K1

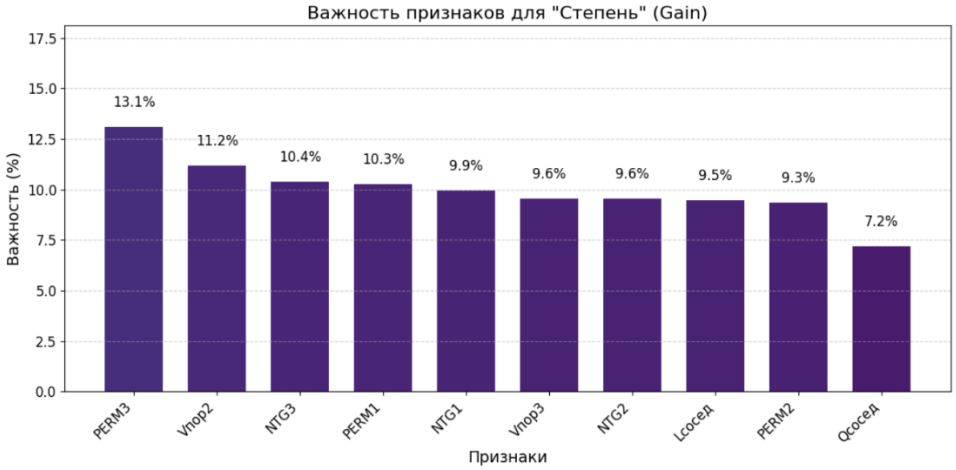

Рис. 8. Степень влияния входных параметров на прогноз коэффициента K2 (степень)

Заключение

Точность адресного прогноза обводнения газодобывающих скважин актуальна как для разрабатываемых, так и для неразрабатываемых газовых залежей, особенно имеющих незначительную газонасыщенную толщину. Опыт разработки газовых залежей и их гидродинамическое моделирование показывают, что время безводной работы добывающих скважин предположительно зависит от нескольких достаточно простых параметров, которые известны и их можно охарактеризовать численными значениями. Однако, надёжную взаимосвязь момента обводнения скважины со значениями этих

параметров установить достаточно проблематично, а альтернативным методом для получения этих взаимосвязей могут стать нейросети или другие методы машинного обучения.

Авторами статьи были созданы синтетические гидродинамические модели нескольких газовых залежей с различным (произвольным) геологическим строением и распределением фильтрационно-ёмкостных свойств. Для каждой геологической реализации были проведены прогнозные расчёты добычи газа с различным числом скважин, различными темпами отбора газа и расположением скважин. Для каждого рассматриваемого сценария получены прогнозные даты начала обводнения скважин и динамика роста водогазового фактора (ВГФ). Таким образом, была сформирована выборка для обучения регрессионной модели XGBoost: в качестве входных переменных использовался набор из 13 оценочных геолого-технологических параметров для каждой скважины, выходные параметры – год начала обводнения каждой скважины и два коэффициента, описывающего степенную функцию роста ВГФ во времени.

Результаты апробации модели показали высокую точность прогноза и многократное сокращение времени получения решения по сравнению с гидродинамическими моделями. В дальнейшем обучающая выборка может быть существенно дополнена новыми результатами гидродинамического моделирования, а также фактическими данными по эксплуатации реальных залежей. Представленная методика имеет перспективы для дальнейшего развития и внедрения на практике.

Список литературы

1. Пономарев А.И., Шаяхметов А.И. Прогнозирование обводнения фонда добывающих скважин на крупных газовых месторождениях. – Уфа, 2014. – 144 с.
2. Усачев В.Д. Разработка методов прогноза обводнения газовых залежей и скважин на базе композиционных гидродинамических моделей. – Москва: дис. канд. техн. наук, 2018. – 116 с.

3. Усачев В.Д., Перемышцев Ю.А. Прогнозирование обводнения газовых залежей водоплавающего типа на примере месторождений Западной Сибири. // Нефтепромысловое дело. 2018. №1. С. 12-17.
4. Гасумов Э.Р. Прогнозирование времени обводнения и самозадавливания газовых скважин (на примере сеноманской залежи) // Евразийский Союз Ученых (ЕСУ). 2020. №8(77). С. 19-22.
5. Милованова В.В., Ибрагимова Д.Р., Захаров Р.В., Красноборов С.В. Прогнозирование обводнения газовых скважин: новый подход с использованием промысловых данных // Инженер-нефтяник. 2021. №1. С. 5-10.
6. Кислицын А.А., Кузнецов С.В., Поднебесных А.В., Грановский А.М. Использование искусственных нейронных сетей для прогнозирования динамики обводнения горизонтальных скважин // Вестник ТюмГУ. Физико-математическое моделирование. Нефть, газ, энергетика. 2019. Том 5. №4(20). С. 160-180.
7. Ибраев А.Е., Камариденова Г.С., Балуанов Б.А., Елемесов А.С. Прогноз обводнённости новых скважин с помощью машинного обучения // Вестник нефтегазовой отрасли Казахстана. Том 5, №3 (2023). С. 20-34.
8. Ibrahim N.M., Alharbi A.A., Alzahrani T.A., Abdulkarim A.M., Alessa I.A., Hameed A.M., Albabtain A.S., Alqahtani D.A., Alsawwaf M.K., Almuqhim A.A. Well Performance Classification and Prediction: Deep Learning and Machine Learning Long Term Regression Experiments on Oil, Gas, and Water Production // Sensors. 2022.

References

1. Ponomarev A.I., Shayahmetov A.I. Prognozirovanie obvodneniya fonda dobivayuschih skvajin na krupnih gazovih mestorojdeniyah. [Forecasting the Watering of Production Wells in Large Gas Fields]. Ufa [Ufa], 2014. – 144 p. (in Russian)
2. Usachev V.D. Razrabotka metodov prognoza obvodneniya gazovih zalejei i skvajin na baze kompozicionnih gidrodinamicheskih modelei [Development of Methods for Forecasting Watering of Gas Deposits and Wells Based on Composite Hydrodynamic Models]. Moskva: dis. kand. tehn. nauk [Moscow: dissertation of the Candidate of Technical Sciences], 2018. – 116 p. (in Russian)
3. Usachev V.D., Peremishcev Yu.A. Prognozirovanie obvodneniya gazovih zalejei vodoplavayuschego tipa na primere mestorojdenii Zapadnoi Sibiri [Forecasting of Watering of Gas Deposits of the Water-Swimming Type on the Example of Deposits in Western Siberia]. Neftepromislovoe delo [petroleum engineering], 2018. №1. P. 12-17. (in Russian).
4. Gasumov E.R. Prognozirovanie vremeni obvodneniya i samozadavlivaniya gazovih skvajin (na primere senomanskoi zaleji) [Prediction of the Time of Watering and Self-Pressure of Gas Wells (Using the Cenoman Deposit as an Example)]. Evraziiskii Soyuz Uchenih [Eurasian Union of Scientists], 2020. №8(77). С. 19-22. (in Russian)
5. Milovanova V.V., Ibragimova D.R., Zaharov R.V., Krasnoborov S.V. Prognozirovanie obvodneniya gazovih skvajin_ novii podhod s ispolzovaniem promislovih dannih [Predicting Water Cut in Gas Wells: A New Approach Using Field Data]. Injener_neftyanik [Petroleum Engineer], 2021. №1. P. 5-10. (in Russian)
6. Kislicin A.A., Kuznecov S.V., Podnebesnih A.V., Granovskii A.M. Ispolzovanie iskusstvennih neironnih setei dlya prognozirovaniya dinamiki obvodneniya gorizontalnih skvajin [Using artificial neural networks to predict the dynamics of water cut in horizontal wells]. Tyumen: Vestnik TyumGU. Fiziko_matematicheskoe modelirovanie. Neft_ gaz_ energetika [Tyumen: Tyumen State University Bulletin. Physical and Mathematical Modeling. Oil, Gas, and Energy], 2019. Volume 5. №4(20). P. 160-180. (in Russian)
7. Ibraev A.E._ Kamaridenova G.S._ Baluanov B.A._ Elemesov A.S. Prognoz obvodnennosti novih skvajin s pomoschyu mashinnogo obucheniya [Predicting the water cut of new wells

using machine learning]. Vestnik neftegazovoi otrasli Kazahstana [Bulletin of the oil and gas industry of Kazakhstan], 2023. - Volume 5, №3. P.20-34. (in Russian)
8. Ibrahim N.M., Alharbi A.A., Alzahrani T.A., Abdulkarim A.M., Alessa I.A., Hameed A.M., Albabtain A.S., Alqahtani D.A., Alsawwaf M.K., Almuqhim A.A. Well Performance Classification and Prediction: Deep Learning and Machine Learning Long Term Regression Experiments on Oil, Gas, and Water Production // Sensors. 2022.

Сведения об авторах

Юшков Антон Юрьевич, кандидат технических наук, старший эксперт по разработке газовых месторождений, ООО «Тюменский нефтяной научный центр», ФГБОУ ВО «Тюменский индустриальный университет»
Россия, 625002, Тюмень, ул. Осипенко, 79/1
E-mail: ayyushkov@tnnc.rosneft.ru

Лычагин Николай Петрович, студент специалитета, ФГБОУ ВО «Тюменский индустриальный университет»
Россия, 625000, Тюмень, ул. Володарского, 38
E-mail: kolia_lichagin2003@mail.ru

Шумейко Руслан Юрьевич, студент специалитета, ФГБОУ ВО «Тюменский индустриальный университет»
Россия, 625000, Тюмень, ул. Володарского, 38
E-mail: russhum@bk.ru

Огуречников Никита Максимович, студент бакалавриата, ФГБОУ ВО «Тюменский индустриальный университет»
Россия, 625000, Тюмень, ул. Володарского, 38
E-mail: nikitka.ogurechnikov@mail.ru

Шумалкин Владислав Сергеевич, студент бакалавриата, ФГБОУ ВО «Тюменский индустриальный университет»
Россия, 625000, Тюмень, ул. Володарского, 38
E-mail: shymalkin3000@gmail.com

Authors

A.Yu. Yushkov, candidate of technical sciences, senior expert on gas field development, Tyumen Petroleum Research Center LLC, Tyumen Industrial University
38, Volodarsky St., Tyumen, 625000, Russian Federation
E-mail: ayyushkov@tnnc.rosneft.ru

N.P. Lychagin, specialist student, Tyumen Industrial University
38, Volodarsky St., Tyumen, 625000, Russian Federation
E-mail: kolia_lichagin2003@mail.ru

R.Yu. Shumeiko, specialist student, Tyumen Industrial University
38, Volodarsky St., Tyumen, 625000, Russian Federation
E-mail: russhum@bk.ru

N.M. Ogurechnikov, bachelor's degree student, Tyumen Industrial University
38, Volodarsky St., Tyumen, 625000, Russian Federation
E-mail: nikitka.ogurechnikov@mail.ru

V.S. Shumalkin, bachelor's degree student, Tyumen Industrial University
38, Volodarsky St., Tyumen, 625000, Russian Federation
E-mail: shymalkin3000@gmail.com

Статья поступила в редакцию 14.07.2025
Принята к публикации 15.12.2025
Опубликована 30.12.2025