

УДК 681.518:622.276

Д.В. Курганов

ОЦЕНКА ЭФФЕКТИВНОСТИ ОБРАБОТОК ПРИЗАБОЙНЫХ ЗОН НЕФТЯНЫХ СКВАЖИН С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Курганов Дмитрий Владимирович, кандидат физико-математических наук, окончил Самарский муниципальный университет, доцент кафедры «Разработка и эксплуатация нефтяных и газовых месторождений» Самарского государственного технического университета. Имеет статьи, патенты в области моделирования процессов разработки нефтяных и газовых месторождений. [e-mail: Dmitri.Kourganov@inbox.ru].

Аннотация

Машинное обучение в настоящее время находит свое применение в самых разных областях науки и техники. Существенным условием для его использования является наличие цифрового фактического материала. За многолетнюю историю эксплуатации нефтяных месторождений накоплена существенная база данных, связанная с разработкой и применяемыми методами стимулирования скважин. В работе рассматривается один из методов машинного обучения для анализа прогнозирования геолого-технических мероприятий (ГТМ) на добывающих нефтяных скважинах. В частности, на примере базы данных с проведенными соляно- и глинокислотными обработками на месторождениях Урало-Поволжского региона и специальных моделях деревьев принятия решений рассчитываются вероятности успешного проведения ГТМ и даются рекомендации по выбору совокупности факторов, позволяющих оптимизировать их проведение. Проницаемость, расчлененность, пластовая температура, текущая обводненность скважин, свойства флюидов – параметры, влияющие на эффективность проведения того или иного ГТМ в скважине. Зачастую их влияние на будущий эффект сложно предугадать, особенно при наличии других факторов. Существующие аналитические модели в полной мере не могут описать все многообразие факторов, участвующих в процессах, проходящих в призабойной зоне скважины, особенно принимая во внимание нелинейные течения, физико-химические взаимодействия пластовых жидкостей и закачиваемых растворов. Описанная же в работе методика позволяет оперировать любым количеством значимых факторов и любой их комбинацией, а также выявлять самые значимые из них, включая описанные параметры, но не ограничиваясь ими. Применение моделей деревьев принятия решений в данном случае является интуитивно понятным способом, позволяющим алгоритмически четко отбирать селективные признаки на каждом уровне. В работе также подробно описывается алгоритм расчета селективного признака. Методы деревьев решений легко могут быть распространены и для решения других задач, стоящих перед нефтедобывающей отраслью, где накоплен большой фактический материал.

Ключевые слова: солянокислотные обработки, глинокислотные обработки, обработки призабойных зон, дебит, нефть, скважина, вероятность, машинное обучение, дерево решений, моделирование.

doi: 10.35752/1991-2927-2020-1-5-47-54

THE CALCULATION OF THE BOTTOMHOLE TREATMENT SUCCESS PROBABILITY USING MACHINE LEARNING TECHNIQUES

Dmitrii Vladimirovich Kourganov, Candidate of Sciences in Physics and Mathematics; graduated from Samara University; Associate Professor at the Department of Oil and Gas Engineering of Samara State Technical University; an author of articles, patents in the field of the modeling of oil and gas field development processes. e-mail: Dmitri.Kourganov@inbox.ru.

Abstract

Machine learning is the most widely used branch of science and engineering nowadays. The availability of electronic real-time information is an important condition for implementing the machine learning. Through the long history of exploitation of oil fields, a significant database related with the wells' development and applied techniques stimulating production was created and accumulated. The article deals with one of the machine-learning methods of analyzing the prediction of geological and engineering operations implemented in the producing oil wells. In particular, by the example of database data including the results of hydrochloric-acid-and-mud-acid jobs implemented in the oil fields of Ural-Volga region, as

well as in terms of specific decision-tree models, the probability of successful geological and engineering operations is calculated, and recommendations on the selection of factors allowing to optimize these operations are given. The openness, average number of permeable intervals, reservoir temperature, actual well watering, fluid properties are parameters influencing the geological and engineering operations efficiency. In many cases, it is difficult to predict the influence in the future especially if other factors are available. The existing analytical models could not describe fully the factor variety in processes running in a bottomhole zone, especially in the context of nonlinear flotations, physical and chemical interaction between formation fluids and injection solutions. The described technique allows using any number of key factors and any combination of them, as well as detecting the most important of them including the parameters described, but not limited to. In this case, the application of decision tree models is an intuitive way allowing to select neatly sampling attributes at each level by the use of algorithms. The article also describes in detail the algorithm of sampling attribute calculation. Decision tree methodology can be used for solving other problems in the oil producing industry with significant practical experience.

Key words: hydrochloric acid treatment, mud acid treatment, bottomhole treatment, yield, crude oil, oil well, probability, machine learning, decision tree, modeling.

ВВЕДЕНИЕ

Методы машинного обучения [1, 2], получившие существенное развитие в последнее время, позволяют по-новому взглянуть на многочисленные фактические результаты, полученные в нефтегазовой отрасли за годы эксплуатации нефтегазовых месторождений. В частности, накоплен большой материал по геолого-техническим мероприятиям (ГТМ) на скважинах в различных коллекторах.

Далее речь пойдет о часто применяющихся на месторождениях ГТМ – обработках призабойных зон (ОПЗ): солянокислотных обработках (СКО) и глинокислотных обработках (ГКО). Будут проанализированы основные условия их применимости, а также дан метод прогнозирования дебита скважины после ГТМ с помощью создания модели дерева решений.

Следует отметить, что предсказание эффекта от проведения того или иного ГТМ на месторождениях традиционно решается с помощью трехмерных геолого-гидродинамических моделей [3, 4], однако зачастую подобные методы имеют низкую прогностическую ценность, поскольку требуется подробнейшее количественное описание как коллектора, так и воздействующей на пласт композиции. Учитывая также реологию, турбулентность, отклонения от стандартных законов фильтрации, не описываемые стандартными уравнениями притока к скважине, подобное решение становится вообще неприемлемым. На помощь приходят различные статистические методы [5], в т. ч. с использованием больших данных [6, 7]. В силу сложностей применения прямых методов прогнозирования процессов повышения нефтеотдачи пластов и ГТМ статистические методы являются более предпочтительными.

Цель исследования

Основной целью работы являются обоснование корректной методики, использующей накопленные данные по ГТМ, свойствам пластов и насыщающих их флюидов, для прогнозирования эффекта (успеха) будущих ГТМ, а

также выбор оптимальных условий для их проведения. Подобная методика призвана упростить формирование решений при управлении разработкой нефтяных месторождений.

Вспомогательные определения. Основными геолого-физическими характеристиками, которые в конечном счете определяют необходимый комплекс технологий для увеличения текущего и конечного коэффициентов нефтеизвлечения объекта, являются [8]:

- глубины залегания объекта,
- характеристика коллектора (карбонатный, трещинный, терригенный, кавернозный),
- режим разработки объекта,
- остаточные извлекаемые запасы,
- расчлененность по разрезу,
- вязкость нефти,
- пластовая температура,
- пластовое давление,
- эффективные толщины,
- абсолютная проницаемость.

Принимая во внимание описанные характеристики, имеется возможность обосновать реализацию крупномасштабных технологий повышения нефтеотдачи пластов (например, полимерное заводнение) либо технологий для локального воздействия (ОПЗ пласта в добывающих и нагнетательных скважинах). Ниже дается краткое описание основных методов воздействия на пласты, для которых были применены технологии машинного обучения.

СКО. Для обеспечения заданных проектных или повышенных отборов нефти рекомендуется применение СКО.

Согласно [9], «...Технология СКО представляет собой направленную обработку призабойной зоны пласта комплексным поверхностно-активным веществом – солянокислотным составом (ПАВ-СКС). Сущность технологии направленной закачки модифицированной соляной кислоты заключается в последовательной многократной порционной закачке в скважину раствора соляной кислоты с ПАВ, вязкой обратной эмульсии (ОЭС) и затем

продавочной жидкости (техническая вода в объеме насосно-компрессорных труб). Закачка кислотных составов в большом объеме приводит к раскрытию существующих микротрещин и образованию новых трещин в карбонатных коллекторах, создает новую геометрию дренирования пласта, увеличивает радиус воздействия на призабойную зону, значительно увеличивает фильтрационные характеристики призабойной зоны пласта».

Эффективность СКО во многом зависит от глубины проникновения кислоты в пласт и от концентрации кислоты в закачиваемом растворе. Оптимальную концентрацию предварительно подбирают в зависимости от геолого-физических свойств коллектора и насыщающих его флюидов.

Для снижения коррозионного воздействия кислоты на оборудование скважин и предотвращения выпадения в пласте окислов железа в раствор кислоты добавляют ингибиторы и стабилизаторы, а для снижения поверхностного натяжения, быстрого и полного извлечения отработанного раствора кислоты и улучшения условий вытеснения нефти из призабойной зоны – ПАВ. Испытания такого рода обработки могут быть рекомендованы в процессе разработки.

БСКО. Для условий пластов, характеризующихся низкими фильтрационно-емкостными свойствами, часто предусматривается проведение большеобъемной солянокислотной обработки (БСКО) – закачки кислотной композиции из расчета не менее $2,5 \text{ м}^3/\text{м}$ вскрытой нефтенасыщенной толщины в соответствии с рассчитанным дизайном. Согласно [10], «...цель БСКО – очистка призабойной зоны пласта от цементной и глинистой корок, продуктов коррозии, солевых отложений, стимуляция матрицы».

Обработке подвергаются следующие скважины:

- новые скважины, давшие при освоении слабый приток нефти;
- неоднократно подвергавшиеся кислотным обработкам, с высоким скин-фактором;
- не вышедшие на расчетную производительность после обычной кислотной обработки (при соблюдении дизайна);
- с обводненностью менее 20%, вскрывшие низкопроницаемый карбонатный коллектор».

Особенности применения технологии – продавка кислотного состава в пласт в объеме, превышающем размеры поврежденной зоны, воздействие на скелет породы, удаленной от призабойной зоны пласта (ПЗП). Для исключения поглощения раствора кислоты наиболее проницаемыми участками призабойной зоны применяются отклонители. В качестве отклонителя рекомендуются загущенный водный раствор полимера – гидроксипропилцеллюлозы (Сульфакселл-2) или реагент СНПХ-9633, образующий высоковязкую эмульсию с пластовой водой (для первой оторочки) и кислотным составом (для отклонения). Технология БСКО широко применяется на низкопроницаемом карбонатном фонде

месторождений ОАО «Самаранефтегаз» (Ветлянского, Утевское, Восточное, Белозерско-Чубовское, Обоинское, Покровское, Западно-Коммунарское, Якушкинское, Сосновское).

ГКО. Согласно [11], «...ГКО рекомендуется для скважин, снизивших продуктивность по причине ухудшения притока жидкости в ходе эксплуатации из-за уменьшения проницаемости ПЗП в результате миграции глинистых частиц и обломочного материала горной породы. Цель обработки – увеличение проницаемости ПЗП. Объект воздействия – кольматирующее вещество и скелет породы.»

ГКО следует осуществлять с большой осторожностью, чтобы не допустить прорыва воды (избегать депрессионного воздействия, глубокого задавливания кислоты в пласт; обработки следует проводить только при низкой обводненности скважины).

Глинокислота по сути является смесью фтористоводородной и соляной кислот. Наибольшее применение данная технология получила для обработки скважин, эксплуатирующих терригенные породы – песчаники, алевролиты и т. д. Глинокислота имеет способность растворять глинистые включения. Это свойство широко используется для обработки глинизированных песчаников, а также для ликвидации глинистых корок со стенок скважины и глинистого раствора, оказавшегося в призабойной зоне в процессе бурения.

Перед проведением обработки обязательно проведение лабораторных опытов на образцах керна и нефти. В опытах сначала исследуется минералогия породы, чтобы обосновать выбор рабочей жидкости. Затем – опыты на совместимость рабочей жидкости и нефти, что нужно для уверенности в том, что при их смешивании не образуется эмульсия или шлам. И, наконец, получают характеристическую кривую кислоты, закачивая рабочую жидкость в очищенные керновые цилиндры при рабочих условиях коллектора (температура и давление) и отслеживая возникающее изменение проницаемости. После этого делают заключение о целесообразности кислотной обработки.

Согласно [11], «...Кислотную обработку песчаниковой матрицы продуктивного пласта осуществляют в следующие три этапа:

- на первом этапе (преднагнетание) закачивают в пласт на 1 м перфорации $0,5\text{--}1,0 \text{ м}^3$ обычного раствора с содержанием 5–15% HCl. Раствор соляной кислоты применяют для растворения небольших количеств карбонатов, содержащихся в песчаниках, и предотвращения их последующего соединения с HF и выпадения осадка CaF_2 ;

- на втором этапе (обработка матрицы) в пласт закачивают без паузы $1,5\text{--}2,5 \text{ м}^3$, а в некоторых случаях до 5 м^3 смеси соляной и плавиковой кислот на 1 м перфорации. Происходит реакция HF с глинами, песком и фильтратом цемента, улучшая проницаемость пласта в призабойной зоне скважины. Соляная кислота из этой

смеси реагирует лишь частично и служит для сохранения кислотности раствора (низкий pH) и, соответственно, препятствует отложению в порах пласта продуктов реакции плавиковой кислоты;

- на третьем этапе (продавка) закачивают в пласт без паузы после раствора второго этапа 15% раствор HCl в том же объеме».

Комбинация HF – HCl различной крепости зависит от проницаемости пласта, содержания алеврита и глины, пластовой температуры. Рабочая концентрация традиционно определяется лабораторным путем.

Методология исследования

Одним из известных методов, положительно зарекомендовавших себя в анализе и классификации фактических данных, является метод деревьев принятия решений [12] – эффективная и, главное, интуитивно понятная методика машинного обучения.

Как правило, алгоритмы создания деревьев решений работают сверху вниз. При этом на каждом этапе выбирается самый селективный фактор, который разбивает исходное множество наблюдений на два подмножества (класса). В каждом подмножестве находятся элементы, максимально близкие друг к другу в смысле определенной метрики.

Одной из интуитивно понятных метрик, которая существенно используется далее, является так называемая мера загрязненности класса. Она измеряет, насколько часто случайный элемент будет неправильно определен по отношению к данному классу.

Метрика представляет собой сумму вероятностей p_i элемента с индексом i , умноженного на вероятность $\sum_{k \neq i} p_k = 1 - p_i$ ошибки выбора данного элемента. Метрика будет равна нулю в случае, если все элементы были выбраны неправильно и попали в чужую категорию.

Для расчета меры загрязненности для множества элементов, попадающих в J классов, положим $i \in \{1, 2, \dots, J\}$ и пусть p_i – это доля элементов, попадающих в класс i . В этом случае мера загрязненности класса рассчитывается следующим образом:

$$\begin{aligned} I_g(p) &= \sum_{i=1}^J p_i \sum_{k \neq i} p_k = \\ &= \sum_{i=1}^J p_i (1 - p_i) = \sum_{i=1}^J (p_i - p_i^2) = \\ &= \sum_{i=1}^J p_i - \sum_{i=1}^J p_i^2 = 1 - \sum_{i=1}^J p_i^2. \end{aligned}$$

Максимальное значение метрики соответственно будет означать, что признак является самым селективным. Далее тот же процесс продолжается для дочерних ветвей, пока не будут выполнены определенные терминальные условия.

Для расчетов меры загрязненности классов были использованы средства MS Excel и встроенный компилятор Visual Basic. Итоговую сложность алгоритма

можно оценить как $O(N \cdot \log N)$, для числа значимых параметров 8 и общей выборке 10000 операций расчет не превышает полминуты на процессоре Intel Core i7-2670QM@2.2GHz.

ИССЛЕДОВАНИЕ

Далее рассматривается пример создания дерева решений, обученного на выборке скважин с проведенными ОПЗ, представляющими собой СКО. Успехом (выходным фактором) будет считаться прирост дебита 5 и более т/сут, неуспехом – соответственно прирост добычи менее 5 т/сут. Данное значение является сугубо индивидуальным для каждого месторождения, оценивается априорно с помощью экономического анализа. Для дальнейшего понимания методологии построения дерева решений абсолютное значение прироста дебита не является принципиальным фактором. В качестве исходной базы взяты данные по месторождениям Самарской и Оренбургской областей (в основном башкирские пласты). Общее количество скважино-операций (выборка) составляет 194, удачных с точки зрения описанного выше критерия – 80%. Следует отметить, что данная выборка не является слишком представительной, однако в методических целях данного количества элементов вполне достаточно. При имеющихся данных метод легко может быть обобщен на большее количество элементов.

Параметрами, которые влияют на успех мероприятия, из эмпирических соображений были выбраны: обводненность продукции скважины, проницаемость пласта, расчлененность пласта, пластовая температура. В общем случае набор признаков может быть шире и включать в себя физико-химические параметры, описанные выше в технологии проведения ОПЗ (концентрация кислоты, соотношение химреагентов и т. д.). Однако для упрощения изложения эти параметры не участвовали в построении деревьев.

Построение стандартных зависимостей прироста выходного фактора от выбранных параметров не раскрывает значимой связи. В частности, проницаемость и прирост дебита после СКО напрямую фактически не связаны (рис. 1), чуть более значимое влияние оказывает




Рис. 1. Зависимость прироста дебита после СКО от проницаемости пласта

обводненность продукции скважины, в которой проводилась СКО (рис. 2).




Рис. 2. Зависимость прироста дебита после СКО от обводненности скважины

Основной задачей на первом этапе построения дерева решения является выбор самого селективного признака. Для этого строится набор таблиц, в которой все множество выбранных параметров разбивается с определенным шагом на интервалы, далее рассчитывается мера загрязненности для каждого полученного значения параметра. Пример в таблице 1 приведен для параметра проницаемости. Обозначения: Comb – комбинированный параметр загрязненности класса, Impurity – загрязненность соответствующего класса для случаев с приростом дебита менее (более) 5 т/сут. В данном случае минимальная загрязненность класса 0,364072 соответствует проницаемости 22 мД. Это означает, что прони-

цаемость в 22 мД является селективным признаком для дерева решений на уровне проницаемости.

Таким же образом строятся все остальные таблицы для всех значимых признаков, в каждой таблице выбирается минимальное значение Comb, которое и соответствует минимальной загрязненности соответствующего класса. Далее можно приступать к конструированию одноуровневого дерева решений. Поступая таким же образом с каждым из параметров, можно выбрать очередной селективный признак (на каждом уровне) и построить многоуровневое дерево для СКО (рис. 3).

Анализируя данный граф, можно, в частности, отметить следующее: самым селективным признаком является обводненность продукции, а не проницаемость, как зачастую считается. Более того, при обводненности более 40%, для успеха мероприятия принципиальным фактором становится расчлененность разреза, которая не столь важна при малых значениях обводненности. При малой расчлененности практически все обработки были эффективны (90%). Далее, если спускаться по правой ветке, можно заметить, что при большой расчлененности (более 2) важна температура пласта – при малой температуре процент успеха низок (всего лишь около 15%). Анализируя основную левую ветку, можно сделать вывод о том, что при низких значениях обводненности продукции важна проницаемость пласта – при ее низких значениях (менее 20 мД) эффект от мероприятия гораздо заметнее.

Аналогичное дерево решений можно построить для ГКО (рис. 4). Для упрощения принято, что успехом также считается прирост дебита более 5 т/сут. Здесь также использована база данных по обработкам скважин Ура-

Таблица 1

Формирование селективного признака на основе проницаемости

Прирост (вправо), м³/сут	<5	>=5	<5	>=5	<5	>5	Comb
Проницаемость (вниз), мД					Impurity	Impurity	
20	14	49	32	97	0,35	0,37	0,364072
22	18	56	28	90	0,37	0,36	0,364350
24	21	65	25	81	0,37	0,36	0,364332
26	22	71	24	75	0,36	0,37	0,364349
28	26	75	20	71	0,38	0,34	0,363660
30	29	79	17	67	0,39	0,32	0,362213
32	32	86	14	60	0,40	0,31	0,361181
34	36	91	10	55	0,41	0,26	0,356842
36	36	96	10	50	0,40	0,28	0,359533
38	39	105	7	41	0,39	0,25	0,358507
40	40	110	6	36	0,39	0,24	0,359127
42	40	120	6	26	0,38	0,30	0,363281
44	41	126	5	20	0,37	0,32	0,363897
46	42	129	4	17	0,37	0,31	0,363774
48	43	134	3	12	0,37	0,32	0,364101



Рис. 3. Дерево принятия решений для СКО (успех: прирост добычи более 5 т/сут)

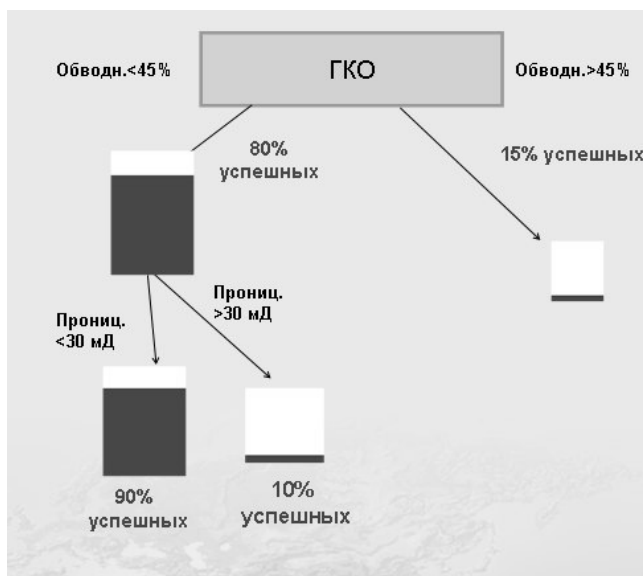


Рис. 4. Дерево принятия решений для ГКО (успех: прирост добычи более 5 т/сут)

ло-Поволжского региона, в основном визейские и девонские пласты. Дерево в данном случае выглядит проще, чем для случая СКО: при обводненности продукции скважины более 45% всего лишь 15% обработок были успешны. Для левой ветки существует еще одно разветвление: при проницаемости менее 30 мД практически все ОПЗ были успешны.

Более простая структура дерева для ГКО, чем для СКО, связана предположительно с тем, что в основном СКО применяются в карбонатных коллекторах, которые зачастую трещиноваты и имеют существенно более сложное строение, чем терригенные [13].

Дальнейшим развитием метода является использование так называемого бэггинга [14]. Известными проблемами многих моделей машинного обучения являются выбросы и проблемы переобучения моделей. Бэггинг способен значительно понизить дисперсию обучаемого классификатора (селективного признака), уменьшая величину, на которую ошибка будет отличаться, если обучать модель на разных наборах данных, таким образом он предотвращает переобучение. Высокая эффективность бэггинга достигается за счет того, что базовые алгоритмы, обученные по различным подвыборкам, получаются существенно различными, а их ошибки взаимно компенсируются при голосовании. Также важен тот факт, что объекты-выбросы могут не попадать в некоторые обучающие подвыборки. Дальнейшее совершенствование описанных методов выходит за рамки данной статьи, однако в работах [14, 15] дается подробное описание этих методов.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Построенные деревья решений позволяют рассчитать вероятность того или иного исхода при разных комбинациях внешних факторов. По сути каждое такое дерево представляет мини-модель отклика системы на изменение пластовых параметров с точки зрения успеха того или иного ГТМ. В прогнозировании эффективности ГТМ можно легко пользоваться такими обучаемыми моделями. Обучив модель на исторических данных, можно распространить результаты на будущие ГТМ и предсказывать эффект от них до непосредственной реализации на скважинах, таким образом существенно удешевляя управление разработкой нефтяных месторождений.

Выводы

Таким образом, разработан алгоритм, по которому можно составить управляющее дерево решений для физико-химических обработок, проводимых на скважинах, и осуществлять управление разработкой месторождения, предсказывать эффект от ГТМ.

Набор анализируемых параметров может быть и увеличен, например, определенной систематизации и применению могут быть подвержены физико-химические свойства раствора, скорость закачки, содержание компонентов и т. п. Отметим лишь, что для этого требуется более широкая выборка данных, отсутствующая в данном случае.

Также в рамках моделей деревьев решений возможна постановка и решение сходных задач, возникающих при управлении разработкой нефтяных и газовых месторождений – например, уплотняющее бурение [16, 17] или перевод скважин под закачку [18]. Необходимым условием проведения подобных исследований является наличие значительного количества уже проведенных скважино-операций, количество которых с каждым годом растет. Поэтому на первое место для успешности методов машинного обучения выступает

обобщение и систематизация исходных данных, полученных от разных нефтепользователей и регионов [19].

СПИСОК ЛИТЕРАТУРЫ

1. Zangl G., Hannerer J. *Data Mining: Applications in the Petroleum Industry*. Katy, TX, Round Oak Publishing, 2003. 222 p.
2. Hand D., Manilla H, Smyth P. *Principles of Data Mining*, USA, MIT-Press, 2001. 546 p.
3. Курганов Д.В. О численном решении одной задачи минимизации в моделировании пластовых систем // Сибирский журнал индустриальной математики. 2003. Т. 6, № 1. С. 51–59.
4. Курганов Д.В. Идентификация параметров математических моделей многофазной фильтрации в нефтяных пластах : дисс... канд.физ.-мат. наук. Самара : Самар. гос. ун-т, 2003. 134 с.
5. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*, USA, Elsevier, 2012. 703 p.
6. Кобзарь А.И. Прикладная математическая статистика. М. : Физматлит, 2006. 628 с.
7. Wu X., Kumar V. *The Top Ten Algorithms in Data Mining*, USA, Taylor & Francis Group, 2009. 201 p.
8. Курганов Д.В., Попков В.И., Хмелевских Е.И. Оценка влияния низкопроницаемых прослоев коллектора на эффективность выработки запасов нефти с использованием трехмерных гидродинамических моделей // Известия Самарского Научного центра РАН. Спец. вып. Проблемы нефти и газа. 2002. С. 121–126.
9. Интенсифицирующий кислотный состав для обработки низкопроницаемых карбонатных коллекторов и терригенных коллекторов с высокой карбонатностью / Л.А. Магадова [и др.] // Нефтяное хозяйство. 2010. № 6. С. 80–83.
10. Комплексный подход к выбору оптимального кислотного состава для стимуляции скважин в карбонатных коллекторах / Р.Я. Харисов [и др.] // Нефтяное хозяйство. 2011. № 2. С. 78–82.
11. Калинин В.Ф. Литолого-физические критерии оптимизации технологии глинокислотной обработки терригенных коллекторов // Известия Саратовского университета. Сер. Науки о Земле. 2007. Т. 7, вып. 1. С. 67–74.
12. Пичугин О.Н., Соляной П.Н., Фатихова Ю.З. От «работы над ошибками» – к прогнозированию эффективности мероприятий // Нефть. Газ. Новации. 2012. № 3. С. 28–32.
13. Колесов В.В., Курганов Д.В. Интегрированное моделирование неоднородности и связности гигантского карбонатного резервуара по геофизическим и промысловым данным на поздней стадии разработки с целью локализации остаточных запасов нефти // Матер. техн. конф. SPE «Разработка зрелых месторождений». М., 2017. С. 121–129.
14. Foreman J.W. *Data Smart: Using Data Science to Transform Information into Insight*, USA, Wiley, 2013. 432 p.

15. Dietterich T.G. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting and Randomization // *Machine Learning*. 2000. Vol. 40. pp. 139–157.

16. Курганов Д.В. Использование многомерной линейной регрессии для прогноза продуктивности коллектора при уплотняющем бурении скважин // *Обзорные прикладной и промышленной математики*. 2019. Т. 26, № 1. С. 78–80.

17. Колесов В.В., Курганов Д.В. Расчет рейтинга скважин-кандидатов при уплотняющем бурении с помощью машинного обучения на промысловых данных (метод опорных векторов) // *Вестник Самарского государственного технического университета. Сер. Технические науки*. 2019. № 1 (61). С. 6–19.

18. Курганов Д.В. Расчет эффекта от перевода добывающей нефтяной скважины в нагнетательный фонд в рамках управления разработкой нефтяным месторождением // *Управление большими системами*. 2019. Вып. 81. С. 147–167.

19. Демьянов В.В., Савельева Е.А. *Геостатистика: теория и практика*. М. : Наука, 2010. 327 с.

REFERENCES

1. Zangl G., Hannerer J. *Data Mining: Applications in the Petroleum Industry*. Katy, TX, Round Oak Publishing, 2003. 222 p.
2. Hand D., Manilla H., Smyth P. *Principles of Data Mining*. USA, MIT-Press, 2001. 546 p.
3. Kurganov D.V. O chislennoem reshenii odnoi zadachi minimizatsii v modelirovanii plastovyykh system [Numerical Solution of One Minimization Problem in Reservoir Simulation]. *Sibirskii zhurnal industrialnoi matematiki* [Siberian Journal of Applied and Industrial Mathematics], 2003, vol. 6, no. 1, pp. 51–59.
4. Kurganov D.V. *Identifikatsiia parametrov matematicheskikh modelei mnogofaznoi filtratsii v neftiannykh plastakh*. Diss. kand.fiz.-mat. nauk [The Parameter Identification of Mathematical Models for Multiphase Filtering in Oil Reservoirs. Cand. Phys. and Math. Sci. Diss.]. Samara, Samara State University Publ., 2003. 134 p.
5. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*. USA, Elsevier, 2012. 703 p.
6. Kobzar A.I. *Prikladnaia matematicheskaia statistika* [Applied Mathematical Statistics]. Moscow, Fizmatlit Publ., 2006. 628 p.
7. Wu X, Kumar V. *The Top Ten Algorithms in Data Mining*. USA, Taylor and Francis Group, 2009. 201 p.
8. Kurganov D.V., Popkov V.I., Khmelevskikh E.I. Otsenka vliianiia nizkopronitsaemykh prosloev kollektora na effektivnost vyrabotki zapasov nefiti s ispolzovaniem trekhmernykh gidrodinamicheskikh modelei [The Estimation of Effect of Low-Permeable Reservoir Layers on Oil Reserves Recovery Using Reservoir Simulation]. *Izvestiia Samarskogo Nauchnogo tsentra RAN. Spets. vyp. Problemy nefiti i gaza* [Proc. of Samara

Scientific Center of RAS. Special Iss. on Problems in Gas and Petroleum Industry], 2002, pp. 121–126.

9. Magadova L.A. et al. Intensifitsiruiushchii kislotnyi sostav dlia obrabotki nizkopronitsaemykh karbonatnykh kollektorov i terrigenykh kollektorov s vysokoi karbonatnostiu [Intensifying Acid Composition for the Treatment of Low-Permeability Carbonate Reservoirs and Terrigenous Reservoirs with High Carbonate Content]. *Neftianoe khoziaistvo* [Petroleum Industry Journal], 2010, no. 6, pp. 80–83.

10. Kharisov R.Ia. et al. Kompleksnyi podkhod k vyboru optimalnogo kislotnogo sostava dlia stimulatsii skvazhin v karbonatnykh kollektorakh [The Complex Approach to the Choice of the Optimum Acid Composition for Well Stimulation in Carbonate]. *Neftianoe khoziaistvo* [Petroleum Industry Journal], 2011, no. 2, pp. 78–82.

11. Kalinin V.F. Litologo-fizicheskie kriterii optimizatsii tekhnologii glinokislotnoi obrabotki terrigenykh kollektorov [Lithological and Physical Yardsticks on Optimization Technology of Mud Acid Treatments Terrigenous Reservoirs]. *Izvestiia Saratovskogo universiteta. Ser. Nauki o Zemle* [Proc. of Saratov University. New Series Earth Sciences], 2007, vol. 7, iss. 1, pp. 67–74.

12. Pichugin O.N., Solianoi P.N., Fatikhova Iu.Z. Ot “raboty nad oshibkami” – k prognozirovaniuu effektivnosti meropriiatii [From “Mistakes Corrected” to Effective Treatment Prediction]. *Neft. Gaz. Novatsii* [Petroleum. Gas. Novations], 2012, no. 3, pp. 28–32.

13. Kolesov V.V., Kurganov D.V. Integrirovannoe modelirovanie neodnorodnosti i sviaznosti gigantskogo karbonatnogo rezervuara po geofizicheskim i promyslovym dannym na pozdnei stadii razrabotki s tseliu lokalizatsii ostatochnykh zapasov nefti [Integrated Modelling of a Giant Carbonate Reservoir Inhomogeneity and Connectivity for Residual Oil Reserves Localization based on Geophysical and Production Data at the Late Stage of

Development]. *Mater. tekhn. konf. SPE “Razrabotka zrelykh mestorozhdenii”* [Proc. of Russian Technology Conf. SPE. Mature Field Development]. Moscow, 2017, pp. 121–129.

14. Foreman J.W. *Data Smart: Using Data Science to Transform Information into Insight*. USA, Wiley Publ., 2013. 432 p.

15. Dietterich T.G. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting and Randomization. *Machine Learning*, 2000, vol. 40, pp. 139–157.

16. Kurganov D.V. Ispolzovanie mnogomernoi lineinoi regressii dlia prognoza produktivnosti kollektora pri uplotniaiushchem burenii skvazhin [Multivariate Linear Regression for Forecasting the Reservoir Performance when Infill Well-Drilling]. *Obozrenie prikladnoi i promyshlennoi matematiki* [Review of Applied and Industrial Mathematics], 2019, vol. 26, no. 1, pp. 78–80.

17. Kolesov V.V., Kurganov D.V. Raschet reitinga skvazhin-kandidatov pri uplotniaiushchem burenii s pomoshchiu mashinnogo obucheniiia na promyslovykh dannykh (metod opornykh vektorov) [Well Ranking for In-Fill Drilling Using Machine Learning with Production and Geological Data]. *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Ser. Tekhnicheskie nauki* [Bull. of Samara State Technical University. Technical Sciences Series], 2019, no. 1 (61), pp. 6–19.

18. Kurganov D.V. Raschet efekta ot perevoda dobyvaiushchei neftianoi skvazhiny v nagnetatelnyi fond v ramkakh upravleniia razrabotkoi neftianym mestorozhdeniem [Calculation of Additional Oil Production after Well’s Conversion to Injector in Oil Reservoir Management]. *Upravlenie bolshimi sistemami* [Large-Scale Systems Control], 2019, iss. 81, pp. 147–167.

19. Demianov V.V., Saveleva E.A. *Geostatistika: teoriia i praktika* [Geostatistics: Theory and Practice]. Moscow, Nauka Publ., 2010. 327 p.