

## ПОВЫШЕНИЕ ТОЧНОСТИ ПРОГНОЗИРОВАНИЯ РЕНТАБЕЛЬНОСТИ НЕФТЕДОБЫВАЮЩИХ СКВАЖИН С ИСПОЛЬЗОВАНИЕМ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ

*Тагирова К.Ф., Вульфин А.М., Шалупов И.С.*

**Ключевые слова:** прогнозирование дебита скважины, машинное обучение, модели характеристик вытеснения, модели регрессии.

**Аннотация.** В статье проанализированы возможности прогнозирования показателей добычи (рентабельности эксплуатации скважины) на основе алгоритмов машинного обучения. Установлено, что применение моделей машинного обучения для прогнозирования показателей добычи нефти, жидкости и воды в сочетании с традиционными моделями характеристик вытеснения позволяет повысить точность прогноза дебита нефти на 10-12% в интервале анализа 12-24 месяца.

## IMPROVING THE ACCURACY OF PREDICTING THE PROFITABILITY OF OIL PRODUCTION WELLS USING INTELLIGENT MACHINE LEARNING TECHNOLOGIES

*Tagirova K.F., Vulfin A.M., Shalupov I.S.*

**Keywords:** well rate forecasting, machine learning, displacement performance models, regression models.

**Abstract.** The article analyzes the possibilities of predicting production indicators (profitability of well operation) based on machine learning algorithms. It has been found that the use of machine learning models for predicting oil, liquid and water production rates in combination with traditional models of displacement characteristics can improve the accuracy of forecasting oil production rates by 10-12% in the analysis interval of 12-24 months.

### Введение

Отрасль нефтедобычи является потребителем самых современных средств автоматизации измерений, контроля, диагностики, управления. Указанные функции выполняются с высокими метрологическими характеристиками (показателями) и позволяют осуществлять управление техническими устройствами, например, режимами работы насосного оборудования, по техническим показателям.

По мере усложнения условий добычи возникает необходимость адаптации технологических режимов с учетом множества влияющих факторов, большинство из которых не могут быть получены путем прямых измерений. В системах управления технологическим процессом добычи нефти широко используется моделирование системы пласт-скважина-скважинное оборудование и отдельных элементов этой системы в зависимости от стадии разработки месторождения. Если раньше это были математические модели, требующие больших затрат не только на разработку и идентификацию, но и на расчет, теперь, с появлением технологий искусственного интеллекта, появляется возможность прогнозного моделирования как режимов, так и комплексных технико-экономических показателей процесса добычи [1, 2].

Представленная статья является развитием [3, 4] авторской концепции построения интегрированной интеллектуальной системы управления процессом добычи нефти. Ранее разработаны методы, структуры, алгоритмы и модели координированного управления процессом добычи нефти по стадиям (поддержание пластового давления, добыча, предварительная подготовка нефти) и уровням (скважина, группа скважин, куст), основанные как на прямых измерениях параметров, так и на расчете моделей объектов и процессов.

Особенностью указанных разработок является включение моделей в структуру систем в виде программных модулей для расчета в соответствующем реальном масштабе времени технических и экономических показателей, на основе которых формируются управляющие воздействия, принимаются решения по переводу скважин, о геолого-технических мероприятиях.

Статья посвящена исследованию возможностей прогнозирования показателей добычи (рентабельности эксплуатации скважины) на основе алгоритмов машинного обучения.

### 1. Объект базовой добычи нефти

Для оценки применимости алгоритмов машинного обучения в задаче прогнозирования добычи нефти рассмотрены основные параметры работы нефтяной скважины одного из нефтяных месторождений в Сибири за период с 2013 по 2021 годы [5]. Глубина скважины составляет 2400 метров. Из скважины жидкость поступает в узел учета, который учитывает долю жидкости и газа, добываемых в сутки. Ежедневно фиксируется процентное содержание воды и нефти. Исходные данные были использованы для оценки не извлечённых запасов, перспектив использования скважины и ее рентабельности. На рисунке 1 приведены основные параметры: ежедневная добыча ( $\text{м}^3$ ) нефти –  $q_n$  (oil\_volume), жидкости  $q_{жс}$  (liquid\_volume) и воды  $q_v$  (water\_volume).

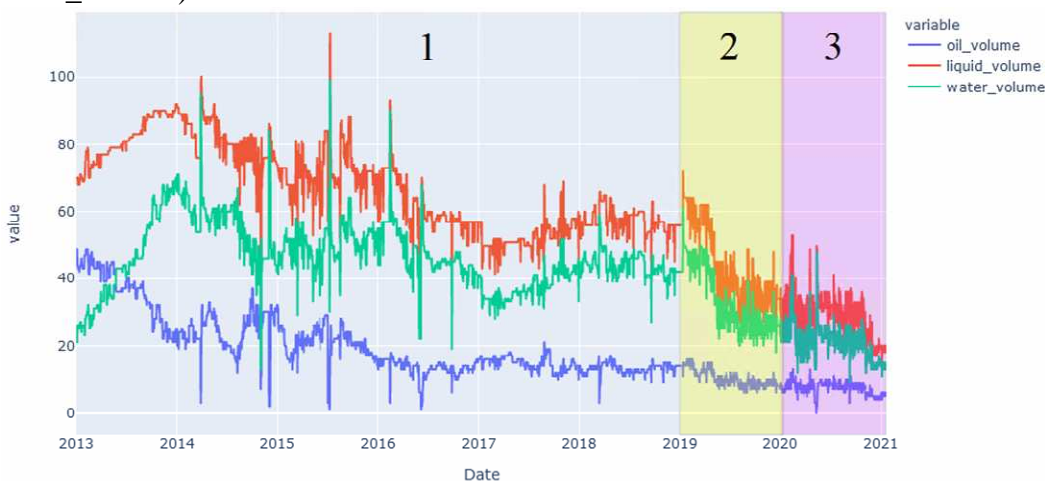


Рис. 1. Ежедневная добыча ( $\text{м}^3$ ) нефти (oil\_volume), жидкости (liquid\_volume) и воды (water\_volume)

Фильтр скользящего среднего с длиной окна анализа равной 30 дням для объема добываемой жидкости позволяет сгладить график зависимости, устранив влияние краткосрочных воздействий, и оценить динамику добычи жидкости (рис. 2).



Рис. 2. Ежедневная добыча ( $\text{м}^3$ ) жидкости (liquid\_volume) и фильтр скользящего среднего с длиной окна анализа в один месяц (MA30)

## 2. Модели прогнозирования дебита жидкости и характеристик вытеснения

Исследование динамики [6] добычи для конкретной скважины позволяет идентифицировать модели характеристики вытеснения и выбирать управляющие воздействия на процессы, происходящие в пласте. Подобные модели широко применяются при прогнозировании добычи нефти и являются основным инструментом оценки технологической эффективности геолого-технических мероприятий (ГТМ). Модель характеристик вытеснения представляет собой совокупность функциональных зависимостей, устанавливаемых для показателей разработки нефтяных месторождений на основе ретроспективных данных. Подобного рода модели описывают динамику роста обводненности.

Построение модели [7] для прогнозирования добычи предполагает отсутствие ГТМ и значительных изменений в системе разработки в течение прогнозного периода таких, как: применение методов увеличения нефтеотдачи и воздействие на призабойную зону пласта. Модели прогнозирования добычи используются для расчета потенциальных извлекаемых запасов нефти на стадии разработки месторождения, когда уже имеется история добычи. Применение для прогнозирования моделей характеристики вытеснения является альтернативой расчетам на полномасштабной геолого-гидродинамической модели.

Интегральные модели аппроксимируют функциональные зависимости между накопленными производственными показателями  $Q_n$  (накопленная добыча нефти),  $Q_w$  (накопленная добыча воды),  $Q_{жс}$  (накопленная добыча

жидкости) и их комбинациями, полученными на основе фактических данных о ежемесячной добыче нефти ( $q_n$ ) и жидкости ( $q_{жс}$ ). Для анализируемой скважины накопленные производственные показатели приведены на рисунке 3.

Одни из наиболее часто применяемых интегральных моделей характеристик вытеснения: Сазонова, Максимова, Пирвердяна и т.д., – приведены в таблице 1.




Рис. 3. Накопленные производственные показатели для анализируемой скважины

Табл. 1. Интегральные модели характеристик вытеснения

№	Название модели характеристики вытеснения	Интегральная форма модели
1.	Сазонова	$Q_n = a \ln(Q_{жс}) + b$
2.	Максимова	$Q_n = a \ln(Q_в) + b$
3.	Пирвердяна	$Q_n = a Q_{жс}^{\frac{1}{2}} + b$

Для получения качественного прогноза необходимо корректно выбрать период квазистационарности накопленных ретроспективных данных, не включающий ГТМ, выполнить их предобработку, выбрать подходящую модель и алгоритм идентификации ее параметров. Интегральные модели характеристик вытеснения применимы при достижении обводненности не менее 30%. Обобщенная схема оценки дебита на основе совокупности моделей представлена на рисунке 4.

На основе ежедневных фактических данных о добыче нефти формируются помесечные показатели добыче нефти ( $q_n$ ), жидкости ( $q_{жс}$ ) и воды ( $q_в$ ), а также строятся (1) соответствующие накопительные производственные показатели  $Q_n$ ,  $Q_в$ ,  $Q_{жс}$ . Выполняется анализ (2) истории изменения фактических и накопленных данных с целью выделения периодов квазистационарности  $\{t_1, t_2\}^i$  для последующего их использования (3) в качестве опорных данных для идентификации параметров моделей добычи нефти, жидкости и воды. Выполняется построение группы моделей (4)

характеристик вытеснения. Если известны значения плановых дебитов  $Q_{жс}$  и  $Q_{в}$ , они используются в качестве прогнозных (4.1). Если плановые дебиты жидкости неизвестны, применяются модели прогнозирования  $Q_{жс}$  или  $Q_{в}$  на основе фактических значений  $q_{жс}$  или  $q_{в}$ , для которых определяется линейный тренд (4.2). Для построения модели [8] прогноза дебита жидкости по каждой скважине на основе данных за период работы может быть использована функция Арпса [9] (4.3). В качестве альтернативы предлагается построение (4.4) ансамбля моделей [10] нелинейной регрессии на основе методов машинного обучения для прогнозирования значений  $q_{нв}$ ,  $q_{жс}$  и  $q_{в}$  с последующим пересчетом соответствующих накопительных характеристик. Подбор (5) гиперпараметров моделей и построение ансамбля на основе технологий бустинга, бэггинга и стекирования позволяет подобрать такие параметры прогностических моделей для фактических значений, которые обеспечивают требуемый уровень аппроксимации функциональных зависимостей в ретроспективных данных.



Рис. 4. Структурная схема оценки дебита нефти на основе анализа ретроспективных данных

Последующая идентификация (6) и отбор (7) моделей характеристик вытеснения совместно с построенным ансамблем моделей-регрессоров позволяет перейти к получению детерминированного прогноза и оценки ошибки на имеющихся данных с целью принятия решения о возможности применения построенных моделей для дальнейшего оперативного управления процессами добычи.

На рисунке 5 представлена схема построения моделей-регрессоров на основе методов машинного обучения, применяемых для прогнозирования значений  $q_{нв}$ ,  $q_{жс}$  и  $q_{в}$  для квазистационарного участка (см. рисунок 1 – желтая зона длительностью 12 месяцев).

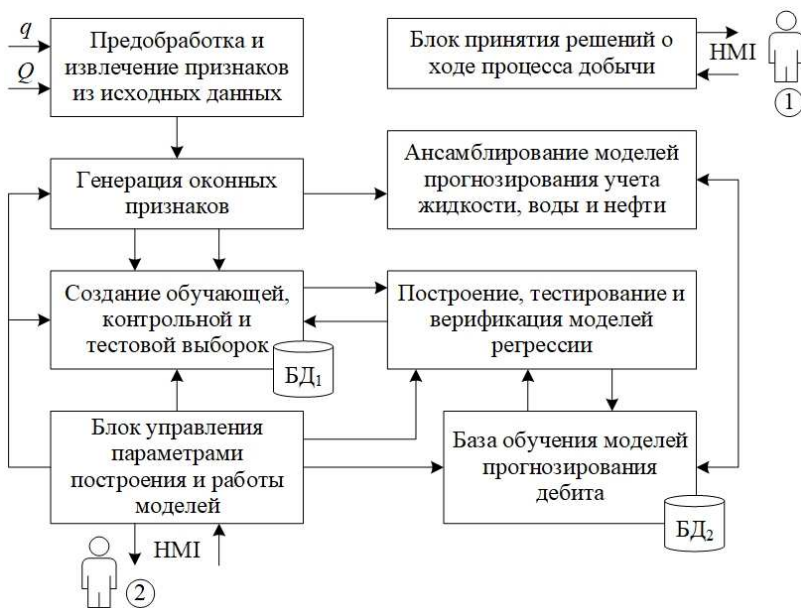


Рис. 5. Схема построения моделей-регрессоров в задаче прогнозирования дебита  $q_n$ ,  $q_{ж}$  и  $q_e$

Предобработка накопленных ретроспективных данных  $q$  и  $Q$  позволяет перейти к извлечению признаков из многомерных временных рядов параметров с помощью метода скользящего опорного окна  $W$  переменной длины с шагом  $S$  и перейти к построению обучающей, тестовой и контрольной выборок (БД<sub>1</sub>). Далее строится семейство моделей регрессии с подбираемыми гиперпараметрами (в том числе, глубиной погружения в многомерный временной ряд параметров и задаваемым горизонтом прогнозирования последующих значений). На основе совокупности метрик, оцениваемых для семейства моделей на контрольной выборке, выбираются те модели, которые демонстрируют наилучшую обобщающую способность (БД<sub>2</sub>). Процессом создания моделей и их валидацией руководит специалист по интеллектуальному анализу данных и машинному обучению (2).

Наилучшие модели включаются в состав ансамбля регрессоров, используемого для поддержки принятия решений о ходе добычи нефти и долгосрочных оценок рентабельности скважин специалистами (1).

### 3. Вычислительный эксперимент

Для эксперимента использованы данные за 24 последних месяца истории добычи из рассматриваемой скважины. С помощью метода наименьших квадратов идентифицированы параметры модели Сазонова за период 2019-2020 год (731 отсчет), используемый в качестве квазистационарного опорного окна. Для тестирования модели использованы данные за период 2020-2021 гг. (384 отсчета) – окно тестирования.

Для построения модели [8] прогноза дебита жидкости на основе данных за выделенный период работы использована функция Арпса:

$$Q_{жс}^n = Q_{жс}^{st} \cdot (1 + k_1 \cdot k_2 \cdot (n-1))^{-\frac{1}{k_2}}, \quad (1)$$

где  $Q_{жс}^n$  – дебит жидкости на текущий расчетный период,  $Q_{жс}^{st}$  – стартовый дебит жидкости,  $k_1$  и  $k_2$  – коэффициенты функции Арпса,  $n$  – номер периода расчета (начиная с 1 и далее).

Идентификация параметров модели Арпса (рис. 6) основывается на минимизации суммы квадратов отклонений расчетных точек дебита жидкости от фактических показателей. Опорными точками для кривой добычи жидкости является среднее трех последних фактических точек. В качестве стартового дебита работы принимается максимальный дебит за историю.

Параметры модели  $k_1 = 0,0064$ ,  $k_2 = -1,3232$ , коэффициент детерминации на тестовых данных –  $R^2 = 0,8359$ .

На основе модели дебита жидкости построена модель характеристик вытеснения Сазонова ( $R^2 = 0,8638$ ) (рис. 7) для опорного окна.

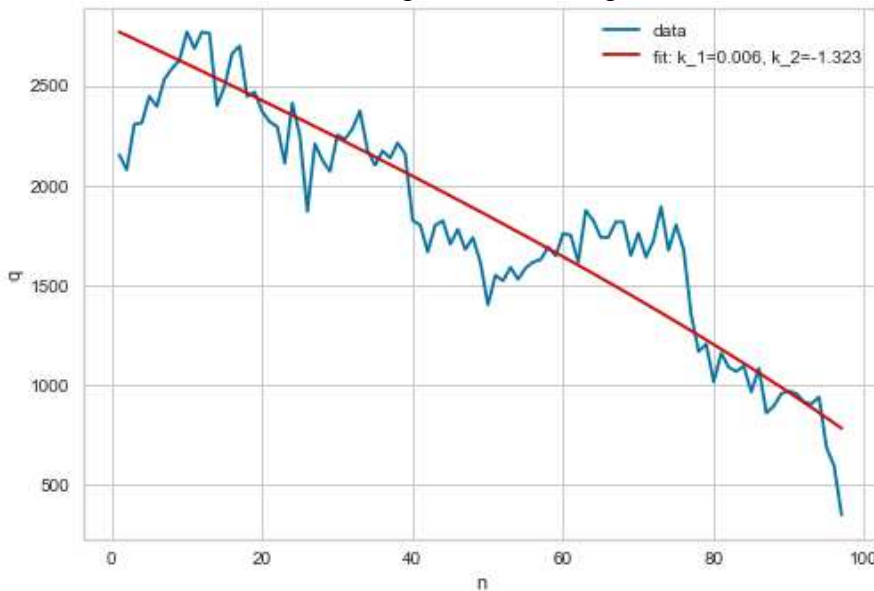


Рис. 6. Прогноз дебита жидкости на основе модели Арпса для анализируемой скважины (ось абсцисс – месяцы, ось ординат – месячный дебит жидкости)

Используя уравнения интегральных моделей характеристик вытеснения и экстраполированные значения  $Q_{жс}$  и  $Q_{в}$ , по модели характеристик вытеснения определяется прогноз  $Q_n$ .

В качестве моделей регрессоров [11, 12], параметры которых подбираются на том же участке квазистационарности ретроспективных данных, использованы модели машинного обучения, указанные в таблице 2. Также приведены метрики качества [13] моделей на контрольных данных для оценки обобщающей способности. Модели упорядочены в порядке убывания метрики суммарной абсолютной ошибки предсказания.

Итоговый ансамбль классификаторов (Voting Regressor), построенный путем стекирования пяти лучших моделей, представлен в таблице 3.




Рис. 7. Модель характеристик вытеснения Сазонова (ось ординат – накопленное значение добычи нефти, ось абсцисс – прологарифмированное значение накопленной добычи жидкости)

Табл. 2. Модели-регрессоры и метрики качества на контрольной выборке

	Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT, sec
<b>huber</b>	Huber Regressor	1,9609	12,7989	2,6580	0,2413	0,1092	0,0718	0,0120
<b>gbr</b>	Gradient Boosting Regressor	4,5551	41,1496	5,0816	-0,2795	0,1407	0,1408	0,0260
<b>ridge</b>	Ridge Regression	4,5638	41,9139	5,5861	-0,2907	0,1698	0,1399	0,5540
<b>xgboost</b>	Extreme Gradient Boosting	4,7986	39,5657	5,4777	-0,2137	0,1588	0,1556	0,0680
<b>par</b>	Passive Aggressive Regressor	4,8613	38,6338	5,9980	-0,2520	0,2215	0,1595	0,4840
<b>br</b>	Bayesian Ridge	4,8779	44,4069	5,9037	-0,3863	0,1778	0,1492	0,5940
<b>dt</b>	Decision Tree Regressor	5,0000	51,4727	6,0314	-0,5855	0,1634	0,1552	0,0080
<b>rf</b>	Random Forest Regressor	5,1407	51,2006	5,8138	-0,5821	0,1654	0,1645	0,0620
<b>omp</b>	Orthogonal Matching Pursuit	5,1872	62,1322	6,8486	-0,8797	0,2304	0,1617	0,5380
<b>catboost</b>	CatBoost Regressor	5,1948	50,0156	5,7816	-0,5522	0,1666	0,1670	0,3400
<b>et</b>	Extra Trees Regressor	5,3174	52,7070	5,8975	-0,6236	0,1665	0,1698	0,0540



Табл. 2. Продолжение

	Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT, sec
<b>ada</b>	AdaBoost Regressor	5,3844	51,8553	6,0017	-0,5941	0,1735	0,1751	0,0280
<b>lightgbm</b>	Light Gradient Boosting Machine	5,5937	62,2390	6,2583	-0,9333	0,1771	0,1796	0,1620
<b>knn</b>	K Neighbors Regressor	5,6575	60,9174	6,3344	-0,8840	0,1803	0,1819	0,0120
<b>lr</b>	Linear Regression	6,0961	62,2078	7,2362	-1,1229	0,2090	0,1853	0,7960
<b>en</b>	Elastic Net	6,1369	78,7227	6,6417	-1,4831	0,1746	0,1846	0,4940
<b>lasso</b>	Lasso Regression	6,1991	82,1926	6,9140	-1,5855	0,1842	0,1837	0,5380
<b>llar</b>	Lasso Least Angle Regression	14,1476	241,2280	15,1752	-6,4079	0,4110	0,4931	0,6480

Табл. 3. Метрики оценки качества ансамбля моделей

Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT, sec
0	Voting Regressor	1,4191	5,0138	2,2391	0,8940	0,0704	0,0493

Распределение остатков предсказания модели для обучающей и проверочной выборок приведены на рисунке 8. Коэффициент детерминации для тестовой выборки составляет  $R^2 = 0,8940$ .

На рисунке 9 приведены опорное окно, использованное для идентификации параметров семейства моделей (2019-2020 гг.) и данные за 2020-2021 гг., использованные для прогнозирования параметра  $q_{жс}$  с помощью ансамбля моделей. Из рисунка видно, что построенный гетерогенный регрессор демонстрирует удовлетворительное качество прогнозирования параметров добычи (область окна тестирования).

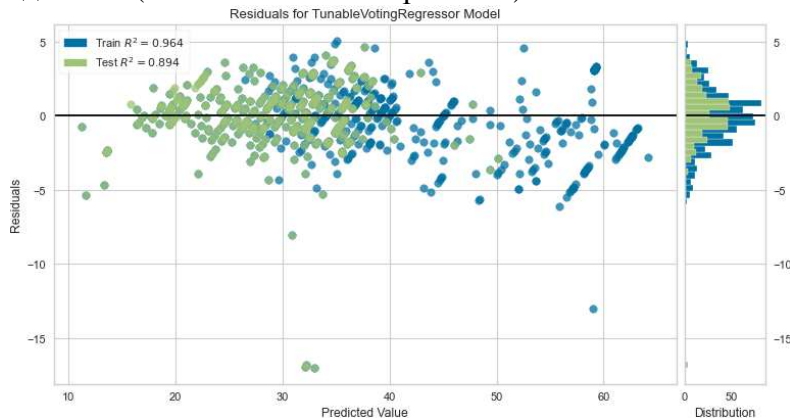


Рис. 8. Распределение остатков по обучающей и проверочной выборкам для ансамбля моделей

Итоговая таблица сравнения ошибки детерминированного прогноза дебита нефти для рассмотренных сценариев применения группы моделей приведена в таблице 4.




Рис. 9. Опорное окно, использованное для идентификации параметров семейства моделей (2019-2020 гг.) и данные за 2020-2021 гг., использованные для прогнозирования параметра  $q_{ж}$  с помощью ансамбля моделей (окно тестирования)

Табл. 4. Сравнительная ошибка детерминированного прогноза дебита нефти

Ошибка детерминированного прогноза, %	Заданное константное значение дебита жидкости	Линейный тренд дебита жидкости	Модель прогнозирования дебита жидкости на основе модели Арпса
Модель прогнозирования дебита нефти на основе модели характеристик вытеснения Сазонова	37,12	30,47	33,36
Модель прогнозирования дебита жидкости, воды и нефти на основе комитета регрессоров	19,94		

Использованы модели прогнозирования дебита нефти на основе модели характеристик вытеснения Сазонова в сочетании с различными вариантами оценки прогнозных накопленных значений добычи жидкости и воды (константные плановые значения, линейный тренд на основе данных опорного окна анализа и прогнозирование с помощью нелинейных моделей Арпса и регрессионные модели машинного обучения). Применение моделей машинного обучения для оценки показателей добычи нефти позволяет повысить точность прогноза на 10-12 % и тем самым уточнить оценки периода рентабельности эксплуатации скважины.

## **Заключение**

В ходе тестирования предложенных решений для детерминированного прогноза дебита нефти установлено, что применение моделей машинного обучения для прогнозирования показателей добычи нефти, жидкости и воды в сочетании с традиционными моделями характеристик вытеснения позволяет повысить точность прогноза дебита нефти на 10-12 % в интервале анализа 12-24 месяца.

*Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-08-01172.*

## **Список литературы**

1. Дьяченко О.И. Методика управления операционной эффективностью эксплуатации нефтегазодобывающих компаний // Экономические науки. 2016. № 145. С. 76-82.
2. Волгин В.А., Михайлов А.Г., Дьяченко О.И. Особенности методического подхода к оценке эффективности работы фонда скважин и повышения его рентабельности // Территория Нефтегаз. 2010. № 11. С. 62-69.
3. Тагирова К.Ф. Управление нефтедобывающим производством по технико-экономическим критериям // Автоматизация, телемеханизация и связь в нефтяной промышленности. 2008. № 5. С. 33-39.
4. Тагирова К.Ф. Повышение эффективности добычи нефти на основе координации управления технологическими процессами и объектами // Вестник УГАТУ. 2008. Т. 10, № 2. С. 48-52.
5. Oil well operation parameters (2013-2021) [Электронный ресурс]. URL: <https://www.kaggle.com/ruslanzalevskikh/oil-well>
6. Назаренко М.Ю. Разработка метода количественной оценки рисков и неопределенности в прогнозе добычи и расчете потенциальных извлекаемых запасов нефти с использованием машинного обучения: дисс. ... канд. техн. наук. – М.: Российский государственный университет нефти и газа, 2021. – 24с.
7. Габитова С.И. и др. Методика прогнозирования темпов падения нефти проектных скважин на основе алгоритма машинного обучения // ПРОнефть. Профессионально о нефти. 2020. № 4. С. 69-74.
8. Рыбаковская А.А. и др. Новый подход в планировании базовой добычи с автоматизацией методики поскважинного расчета // ПРОнефть. Профессионально о нефти. 2021. Т. 6, № 2. С. 45-49.
9. Вальес-Лосано Дж., Репин-Поляков Н.Н. Применение метода кривой падения Арпса для прогноза дебита скважины // Наука, техника и образование. 2020. № 5 (69). С. 12-15.
10. Евсюткин И.В., Марков Н.Г. Глубокие искусственные нейронные сети для прогноза значений дебитов добывающих скважин // Известия Томского политехнического университета. Инжиниринг георесурсов. 2020. Т. 331, № 11. С. 88-95.

11. Rong S., Bao-wen Z. The research of regression model in machine learning field // MATEC Web of Conferences. EDP Sciences. 2018. Vol. 176. P. 01033.
12. Huang J.C. et al. Application and comparison of several machine learning algorithms and their integration models in regression problems // Neural Computing and Applications. 2020. Vol. 32, № 10. P. 5461-5469.
13. Botchkarev A. Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology // arXiv preprint arXiv:1809.03006. 2018.

### References

1. Diachenko O.I. The method of oil and gas fields operational efficiency management // Economic sciences. 2016. No. 145. P. 76-82.
2. Volgin V.A., Mikhailov A.G., Diachenko O.I. Features of the methodological approach to assessing the efficiency of the well stock and increasing its profitability // Oil and gas territory. 2010. No. 11. P. 62-69.
3. Tagirova K.F. Oil production management according to technical and economic criteria // Automation, telemechanization and communication in the oil industry. 2008. No. 5. P. 33-39.
4. Tagirova K.F. Improving the efficiency of oil production based on coordinated management of technological processes and facilities // Bulletin of USATU, 2008. Vol. 10, № 2. P. 48-52.
5. Oil well operation parameters (2013-2021). Available at: <https://www.kaggle.com/ruslanzalevskikh/oil-well>
6. Nazarenko M.Yu. Development of a method for quantitative assessment of risks and uncertainties in forecasting production and calculating potential recoverable oil reserves using machine learning: diss. ... cand. Of tech. sc. – M.: Russian State University of Oil and Gas, 2021. – 24p.
7. Gabitova S.I. et al. A new method of decline curve forecasting for project wells on the base of machine learning algorithms // PROneft. Professionals about oil, 2020. No. 4. P. 69-74.
8. Rybakovskaya A.A. et al. Automation of the forecasting process for wells base production // PROneft. Professionals about oil. 2021. Vol. 6. No. 2. P. 45-49.
9. Valles-Lozano J., Repin-Poliakov N.N. Application of the ARPS decline curve analysis method for forecasting well debit // Science, technology and education. 2020. No. 5(69). P. 12-15.
10. Evsyutkin I.V., Markov N.G. Deep artificial neural networks for predicting production well rates // Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering. 2020. Vol. 331. No 11. P. 88-95.
14. Rong S., Bao-wen Z. The research of regression model in machine learning field // MATEC Web of Conferences. EDP Sciences. 2018. Vol. 176. P. 01033.
15. Huang J.C. et al. Application and comparison of several machine learning algorithms and their integration models in regression problems // Neural Computing and Applications. 2020. Vol. 32, № 10. P. 5461-5469.

11. Botchkarev A. Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology // arXiv preprint arXiv:1809.03006. 2018.

<b>Вульфин Алексей Михайлович</b> – кандидат технических наук, доцент, vulfin.alexey@gmail.com	<b>Vulfin Alexey Mikhailovich</b> – candidate of technical sciences, associate professor, vulfin.alexey@gmail.com
<b>Тагирова Клара Фоатовна</b> – доктор технических наук, профессор, tagirovakf@yandex.ru	<b>Tagirova Klara Foatovna</b> – doctor of technical sciences, professor, tagirovakf@yandex.ru
<b>Шалупов Иван Сергеевич</b> – магистрант, shalupov.ivan@yandex.ru	<b>Shalupov Ivan Sergeevich</b> – master's student, shalupov.ivan@yandex.ru
Уфимский государственный авиационный технический университет, Уфа, Россия	Ufa State Aviation Technical University, Ufa, Russia

*Received 20.12.2021*