

МЕТОДИКА ПРОГНОЗИРОВАНИЯ ТЕМПОВ ПАДЕНИЯ НЕФТИ ПРОЕКТНЫХ СКВАЖИН НА ОСНОВЕ АЛГОРИТМА МАШИННОГО ОБУЧЕНИЯ

**С.И. Габитова¹, Л.А. Давлетбакова¹, В.Ю. Климов¹, Д.В.Шуваев¹,
И.Я. Эдельман², С. Шмидт²**

¹ Научно-Технический Центр «Газпром нефти» (ООО «Газпромнефть НТЦ»),

² Салым Петролеум Девелопмент Н.В.

Электронный адрес: Gabitova.SI@gazpromneft-ntc.ru

Разработан метод, интегрирующий ручное выделение групп и алгоритм машинного обучения, позволяющий прогнозировать с высокой точностью темпы падения нефти проектных скважин по двум входным параметрам. При помощи машинного обучения (МО) выявлены скрытые закономерности между входными параметрами и темпами падения скважин. Анализ темпов падения скважин по типу заканчивания проиллюстрировал, что горизонтальные скважины эффективнее, чем наклонно-направленные.

Ключевые слова: темп падения добычи нефти, кластеризация, классификация, оценка достаточности, алгоритмы машинного обучения

A NEW METHOD OF DECLINE CURVE FORECASTING FOR PROJECT WELLS ON THE BASE
OF MACHINE LEARNING ALGORITHMS

**S.I. Gabitova¹, L.A. Davletbakova¹, V.Yu. Klimov¹, D.V. Shuvaev¹,
I.Ya. Edelman², S. Shmidt²**

¹ Gazpromneft NTC LLC, RF, Saint-Petersburg

² Salym Petroleum Development N.V., RF, Moscow

The article describes new decline curves (DC) forecasting method for project wells. The method is based on the integration of manual grouping of DC and machine learning (ML) algorithms appliance. ML allows finding hidden connections between features and the output. Article includes the decline curves analysis of two well completion types: horizontal and slanted wells, which illustrates that horizontal wells are more effective than slanted.

Keywords: decline curve, clustering, classification, sample sufficiency, machine learning algorithms

DOI: 10.7868/S2587739920040102

ВВЕДЕНИЕ

В настоящее время перед нефтяными компаниями стоит важная задача добиться максимально эффективной разработки месторождений. Данная задача актуальна для базового и проектного фонда скважин. С целью оценки и прогнозирования профилей добычи базового фонда и проектных скважин применяются гидродинамические модели и единые эмпирические зависимости для участков месторождений. Первые требуют высоки временных затрат, вторые обладают низкой степенью достоверности прогноза ввиду отсутствия учета геолого-физических характеристик (ГФХ) и ввиду сильного осреднения показателей на единичную скважину, что сильно сказывается на точности прогнозирования для зон с высокой дифференциацией свойств пласта. В связи с этим возникает необходимость создания метода, позволяющего на основе ГФХ прогнозировать

с высокой точностью динамику падения добычи по проектным скважинам с минимальной затратой времени. Целью данной работы является создание метода для прогнозирования темпов падения проектных скважин по входным геолого-физическим характеристикам. Для этого решалась задача создания классификатора, который использует методы машинного обучения (МО). Реализация осуществлялась при помощи языка программирования Python 3.0. Данный метод также позволяет провести сравнительный анализ динамики ТПГС и ННС.

МЕТОД ПРОГНОЗИРОВАНИЯ ТЕМПОВ ПАДЕНИЯ

Первый этап включает в себя формирование выборки, сбор входных данных. Перед проведением анализа были сформированы критерии, которым должны соответствовать

по скважине № 219 (ТС4), что в дальнейшем с высокой степенью достоверности позволит оценивать показатели добычи проектного фонда скважин.

ЗАКЛЮЧЕНИЕ

Проведен анализ влияния геолого-технологических факторов на показатели добычи, а также предложен подход к прогнозированию добычи нефти скважин баженновской свиты по методу доверительного интервала со скользящим стандартным отклонением. Прогноз показателей (дебит нефти, накопленная добыча) представлен в виде вероятностных диапазонов, изменяющихся по степенной зависимости от величины влияния геолого-технологических факторов. С целью эффективного проведения анализа сформирована матрица данных, включающая более 350 параметров, характеризующих геологические, геомеханические и технологические факторы. Основное влияние на продуктивные характеристики скважин оказывают технологические факторы, характеризующие количественные и качественные параметры закачиваемых в пласт жидкостей и проппанта при ГРП. Обнаружена корреляция между типом

жидкости ГРП и величиной стимулированного объема пласта (SRV), которая влияет на показатели добычи нефти анализируемого фонда. Сформированы комплексные параметры, характеризующие добычу нефти по скважинам. Наряду со статистическим методом построения корреляций рассмотрены регрессионные модели машинного обучения, реализованные на языке Python. Установлено, что параметры, влияющие на показатели добычи, в большинстве случаев совпадают с результатами статистического анализа. На основе проведенного анализа выполнена оценка показателей добычи нефти для проектного фонда скважин. Ретроспективный анализ проверки прогнозных показателей и на фактически действующей скважине показал сходимость результатов. Подходы по оценке параметров, влияющих на формирование добычи, и прогнозных показателей при работе со сверхнизкопроницаемыми коллекторами высокой степени неопределенности их геолого-геомеханических свойств, рассмотренные в статье, будут способствовать дальнейшему развитию методической основы для работы с другими объектами подобной сложности.

Список литературы

1. D.Ilk, DeGolyer, MacNaughton, Jenkins C.D., DeGolyer, MacNaughton, Blasingame T.A. Texas A&M University. Production analysis in unconventional reservoirs – Diagnostics, Challenges, and Methodologies. Society of petroleum engineers. SPE144376. 2011.
2. Velasco R., Panja P., Deo M. New production performance and prediction tool for unconventional reservoirs. Unconventional Resources Technology Conference (URTeC). 2016. – doi: 10.15530/urtec-2016-2461718
3. Seber G.A.F., Lee A.J. Lineyniy regressionnyy analiz [Linear regression analysis]. – Auckland: John Wiley & Sons, 2012. – Т. 329.

References

1. Ilk D., Jenkins C.D., Blasingame T.A. Production Analysis in Unconventional Reservoirs – Diagnostics, Challenges, and Methodologies. *North American Unconventional Gas Conference and Exhibition, 14–16 June, The Woodlands, Texas, USA*. 2011.
2. Velasco R., Panja P., Milind D. New Production Performance and Prediction Tool for Unconventional Reservoirs. *Unconventional Resources Technology Conference (URTeC)*. 2016. doi: 10.15530/urtec-2016-2461718
3. Seber G.A.F., Lee A.J. *Lineyniy regressionnyy analiz* [Linear regression analysis]. Auckland, John Wiley & Sons, 2012. Vol. 329.

скважины. Для исследования использовались данные скважин, которые:

- 1) были запущены в эксплуатацию с 01.01.2014 г.
- 2) работают более 6 мес.,
- 3) не работающие в периодическом режиме (АПВ) более 6 мес. с начала эксплуатации,
- 4) переведенные на постоянный режим работы после проведенного гидроразрыва пласта (ГРП).

МЕТОДИКА ПОЗВОЛЯЕТ БЫСТРО, С ВЫСОКОЙ ТОЧНОСТЬЮ ОЦЕНИВАТЬ И ПРОГНОЗИРОВАТЬ ТЕМП ПАДЕНИЯ ПРОЕКТНОЙ СКВАЖИНЫ ПРИ ДВУХ ВХОДНЫХ ПАРАМЕТРАХ, КОТОРЫЕ МОЖНО СНЯТЬ С ПРОГНОЗНЫХ КАРТ. ПРЕДЛОЖЕН АЛГОРИТМ СОЗДАНИЯ КЛАССИФИКАТОРА НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ.

Были исключены скважины, работающие совместно на разных объектах разработки. Для построения темпов падения добычи выбираются стартовые дебиты, которые определяются как экстремумы в начальный период времени (за первые 3 мес.). Необходимо деление скважин по типу заканчивания (ГС или ННС) и далее выборка на группы при наличии сложных геолого-технологических мероприятий (ГТМ) на скважинах (ГРП или многостадийный гидроразрыв пласта (МГРП)). Проводится сбор входных данных по каждой скважине: параметры, которые можно снять с карт – проницаемость, мД (к), пористость, д. ед. (рого), нефтенасыщенные толщины (ННТ),




Рис. 1. Пример построения аппроксимированной кривой ТП. Красная линия – фактический темп падения, сплошная синяя – аппроксимированный темп падения по Арпсу и пунктирная линия – экстраполяция аппроксимированного темпа падения

м (netpay), нефтенасыщенность, д. ед. (soil), kh, добычные характеристики (сложнопрогнозируемые параметры) – стартовая обводненность (WC), обводненность через 6 мес. (WC6), обводненность через 12 мес. (WC12), расчлененность (r).

На втором этапе проводится оценка достаточности выборки, которая осуществляется при помощи критерия t -Стюдента. Для анализа требуется оценка динамики в одинаковый период времени, однако, фактический период работы скважин разный, в связи с чем расчет производится на аппроксимированных темпах падения (применен степенной Арпс). Далее, с помощью полученных кривых падения строится прогноз на необходимый период времени для каждой скважины [1]. Пример построения аппроксимированного темпа падения на основе степенного Арпса представлен на рис. 1.

Существующие методы оценки достаточности выборки не позволяют оценивать такие динамические параметры, как темпы падения (в каждом месяце скважине соответствует свое значение ТП добычи). В связи с этим создана методика, ориентированная на оценку достаточности выборки динамических параметров. Значения темпов падения по всем скважинам за каждый месяц рассматриваются как отдельные выборки, по которым проводится оценка достаточности. Далее приведен алгоритм выборки оценки достаточности на один месяц. Репрезентативность входных данных – важный фактор, поэтому проводится проверка на выбросы. Анализируются максимальное и минимальные значения со значениями в выборке [2]. Достаточность выборки подтверждается при выполнении условия: доверительная вероятность равна 0,95. Необходимый объем выборки рассчитывается по формуле (1). Принимаем, что относительная погрешность (Δ) нахождения среднего равна 10%. Полученное значение округляем до меньшего целого:

$$n_p = \left\lceil \frac{t_{y,n} \cdot S_x}{\Delta \cdot \bar{X}} \right\rceil, \quad (1)$$

где $t_{y,n}$ – коэффициент Стюдента; S_x – среднее квадратическое отклонение; $\bar{X}$ – выборочное среднее. Полученные расчетные значения отображаются на графике динамики изменения необходимого объема выборки, пример представлен на рис. 2, а. Выборка считается репрезентативной до тех пор, пока кривая фактического количества скважин выше необходимого количества.

Если необходимое количество значений в выборке превышает текущее, то текущая выборка может не стать репрезентативной при добавлении необходимого количества значений. Следует проводить повторный расчет по определению




Рис. 2. Пример группирования ТП (а) и оценка достаточности рассматриваемой группы (б)

необходимого количества значений в данной выборке при изменении входной информации. Третий этап – кластеризация скважин по темпам падения. Перед выделением кластеров проводится анализ входных данных при помощи построения тепловой диаграммы, которая отображает линейную корреляцию между парой параметров. Согласно максимальным значениям корреляции, проводится кластеризация темпов падения. Выполнено тестирование нескольких методов автоматической кластеризации. Кластеризация темпов падения по сочетаниям параметров при помощи алгоритма K-Means (МО) показала низкую результативность ввиду отсутствия одинаковых трендов темпов падения скважин в группах. Иерархическая кластеризация динамических признаков – темпов падения – также показала низкую эффективность.

Ручное группирование по выделенным высоким корреляциям сложнопрогнозируемых параметров (добычные характеристики) в тепловой диаграмме позволило успешно выделить группы по темпам падения, которые были оценены на достаточность выборки при помощи критерия t -Стюдента. На примере наклонно-направленных скважин выделены следующие группы: с высоким темпом падения обводнения, с низким темпом падения обводнения и с аномально высоким темпом падения нефти. Группа с низким темпом обводнения и динамическая оценка достаточности выборки представлены на рис. 2, а и б соответственно. На основе средних значений аппроксимированных темпов падения (красная линия) выделен базовый сценарий темпов падения (сплошная зеленая линия) по модели Арпса. Выборка рассматриваемой группы является репрезентативной до 20-го месяца.




Рис. 3. Результаты кластеризации ННС (а) и расположение скважин на карте Салымской группы месторождений (б). Красная, синяя и зеленая линии – аппроксимированные темпы падения на средних аппроксимированных значениях для 1, 2 и 3 групп соответственно, на рис. а и б

Результаты группирования приведены на **рис. 3, а**. Анализ расположения групп на карте (**рис. 3, б**) Салымской группы месторождений позволяет утверждать, что скважины не группируются по площади и явной зависимости между параметрами (геолого-физическими характеристиками) не наблюдается. В связи с этим возникает необходимость применения алгоритма МО, который способен устанавливать взаимосвязи между входными признаками – простыми параметрами, которые можно снять с прогнозных карт, а также который позволит прогнозировать с высокой точностью темп падения проектной скважины на основе этих параметров.

После проведения группирования темпов падения следующим этапом является поиск оптимального алгоритма машинного обучения с учителем для верификации ручной кластеризации, нахождения скрытых взаимосвязей между входными параметрами, которые можно снять с карт (геолого-физическими характеристиками), и выделенными группами темпов падения. При выборе алгоритма МО учитываются следующие критерии: принимаются параметры, при которых точность на обучающей и тестовой выборке стремится к 100%, и ведется поиск наименьшего количества входных параметров, которые можно снять с прогнозных карт. Входные параметры обучения – ГФХ и добычные характеристики по скважинам. Целевая функция – группа, к которой отнесена скважина (результаты ручной кластеризации). Проверка качества модели осуществлялась по способу отложенной выборки. Разбиение выборки на обучающую и тестовую проводится случайным образом в соотношении 80% к 20% [3]. Метрикой оценки результатов являлась точность прогноза. Во время выполнения анализа полученной выборки были рассмотрены алгоритмы методов машинного обучения с классификацией по прецедентам:

- метод бустинга – Gradient Boosting Classifier (GBC), CatBoostClassifier, XGBoost;
 - метод бэггинга – Random Forest;
 - метод опорных векторов – SVM;
 - метод ближайших соседей – KNN (K-Nearest Neighbors);
 - метод осреднения – Gradient Boosting Classifier + KNN, CatBoostClassifier + KNN;
 - метод блендинга – Gradient Boosting Classifier + KNN.
- Настройка параметров осуществлялась кросс-валидацией при помощи GridSearchCV. В результате наилучшую прогнозную способность показали алгоритмы, основанные на методе бустинга.
- В качестве примера представлен результат поиска модели для группы ННС и варьирования количества входных признаков модели от 1 до 9. Из полученных моделей выбирается наилучшая. Результаты по методам осреднения моделей GBC + KNN и XGBoost представлены в **табл. 1**, где зеленым цветом окрашены параметры, которые можно снять с прогнозных карт, синим выделены сложнопрогнозируемые параметры.
- Анализ проведенных тестов позволяет сделать вывод о том, что наибольшую прогнозную способность (82 и 98% на тестовой и обучающей выборке соответственно) показал алгоритм XGBoost при использовании входных признаков, снятых с карт (проницаемость и нефтенасыщенность). При использовании сложнопрогнозируемых параметров точность прогноза выше, но для прогнозирования данных параметров требуются дополнительные исследования и расчеты. Наивысшую точность показывает модель, основанная на алгоритме градиентного бустинга над решающими деревьями, которая позволяет уменьшать ошибку переобучения за счет построения ансамблей деревьев решений, каждое из которых освещено об ошибках предыдущих [4].

Таблица 1. Результаты применения алгоритмов МО при двух входных параметрах

Метод	Обучающая выборка (точность, %)	Тестовая выборка (точность, %)	Параметр 1	Параметр 2
Averaging GBC + KNN	85	91	k	deltaWC12
	83	82	soil	kh
	75	73	k	soil
	80	64	netpay	soil
	78	55	netpay	kh
XGBoost	98	91	WC	deltaWC6
	98	82	k	soil
	95	73	k	kh
	100	64	k	netpay
	100	64	k	WC

РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ МЕТОДИКИ. Анализ динамики темпов падения наклонно-направленных и горизонтальных скважин

Предложенный метод применен на горизонтальных и вертикальных скважинах Салымской группы месторождений. Далее представлены результаты, полученные на основе выборки скважин, без проведенных ГТМ (ГРП/МГРП).

На первом и втором этапах для ГС были собраны входные параметры, построены темпы падения и проведена оценка достаточности генеральной выборки. Визуальная ручная кластеризация ТП ГС позволила сформировать три группы: группу 1 и группу 2 с высоким темпом падения, группу 3 с низким темпом падения (**рис. 4**, сплошные линии). Для ННС также были сформированы группы (**рис. 4**, пунктирные линии).

Проведенный анализ достаточности выборки позволил утверждать, что группы 1 и 2 репрезентативны до 20 мес., группа 3 не репрезентативна и требует включения дополнительных ТП по скважинам. Для ННС анализ достаточности показал, что группа 1 репрезентативна до 11 мес., группа 2 – до 23 мес., группа 3 – нерепрезентативна и требует включения дополнительных скважин. При выборе алгоритмов МО для прогноза принадлежности проектной скважины к одной из выделенных групп наибольшую точность показали модели градиентного бустинга.

Разбиение на группы темпов падения горизонтальных скважин и наклонно-направленных скважин позволяет сравнить эффективность работы скважин (**рис. 4**). Сплошные линии соответствуют темпам падения ГС, пунктирные – темпам падения ННС.

При сравнении первых групп (красные линии) темп падения ННС больше, чем у группы ГС. Более резкое падение ТП ННС происходит из-за истощения (слабое влияние системы поддержания пластового давления), динамика темпов падения горизонтальных скважин более медленная из-за хорошо выстроенной системы ППД. Количество горизонтальных скважин группы 1 – это 19% от их репрезентативной выборки и количество наклонно-направленных скважин группы 1 – 35% от их репрезентативной выборки.

Тренд темпа падения группы 2 ННС и ГС (зеленые линии) до 6-го месяца одинаковый. Однако после ТП ННС увеличивается в связи с ростом обводненности (скважины находятся в высокопроницаемых пластах с наличием подстилающей воды), а рост обводненности ГС, пробуренных в кровельных частях пласта, с наличием подстилающей воды более медленный.




Рис. 4. Темпы падения групп ГС и ННС

Ко второй группе относятся 77% горизонтальных скважин, тогда как наклонно-направленных – 49%.

Тренды темпов падения группы 3 ННС и ГС показаны линиями синего цвета на **рис. 4**. Резкое падение ТП ГС в начальный период времени обусловлено поздним запуском системы поддержания пластового давления, и далее кривая выравнивается за счет ее оптимизации (резкое падение останавливается). Более медленный темп падения ННС объясняется за счет меньшего охвата при позднем запуске системы ППД или от ее перекомпенсации. Процентное количество горизонтальных скважин – 4%, наклонно-направленных – 16%.

В результате проведенного анализа установлено, что горизонтальные скважины эффективнее, чем наклонно-направленные.

Выводы

Авторами разработана методика, которая позволяет быстро, с высокой точностью оценивать и прогнозировать темп падения проектной скважины при двух входных параметрах, которые можно снять с прогнозных карт. Предложен алгоритм создания классификатора на основе машинного обучения для определения типа темпов падения и оценки достаточности выборок для прогнозируемого периода с целью дальнейшего расчета добычи нефти. По результатам сравнительного анализа динамики темпов падения ГС и ННС, горизонтальные скважины эффективнее наклонно-направленных.

Список литературы

1. Analysis of Decline Curves [Text] / Arps, J.J. // AIME. – 1945. – V. 160. – P. 228–247. <https://doi.org/10.2118/945228-G>
2. Планирование и организация эксперимента [Текст]: учебное пособие для студентов / А.Г. Левшин [и др.]. – М.: Изд-во РГАУ-МСХА, 2015. – 65 с.
3. Орельен Ж. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow. Концепции, инструменты и техники для создания интеллектуальных систем [Текст]. – Изд-во Вильямс, 2018. – 688 с.
4. Shalev-Shwartz Sh., Ben-David Sh. [Текст]: Understanding Machine Learning Algorithms: From Theory to Algorithms. – Cambridge: Cambridge University Press, 2014. – 449 с.

References

1. Arps J.J. Analysis of Decline Curves. *Transactions of the AIME*. 1945, vol. 160, no. 1, pp. 228–247. doi: 10.2118/945228-G
2. Levshin A.G. et al. *Planirovanie i organizatsia experimenta* [Planning and organizing of experiment]. Moscow, RGAU-MSKhA, 2015. 65 p.
3. Geron A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media Inc., 2018. 718 p.
4. Shalev-Shwartz Sh., Ben-David Sh. *Understanding Machine Learning Algorithms: From Theory to Algorithms*. Cambridge, Cambridge University Press, 2014. 449 p.

ВИРТУАЛЬНАЯ РАСХОДОМЕТРИЯ КАК ИНСТРУМЕНТ МОНИТОРИНГА ЭФФЕКТИВНОСТИ РАБОТЫ СКВАЖИНЫ С УЭЦН

А.М. Андрианова¹, А.А. Логинов¹, Р.А. Хабибуллин¹, О.С. Кобзарь²

¹ Научно-Технический Центр «Газпром нефти» (ООО «Газпромнефть НТЦ»),

² Инжиниринговый центр МФТИ по трудноизвлекаемым полезным ископаемым

Электронный адрес: Andrianova.AM@gazpromneft-ntc.ru

В статье рассматриваются актуальность и различные способы применения задачи виртуальной расходомерии, приведены методы решения задачи, используемые в отрасли. Подробно разобран подход, основанный на анализе работы установки электрического центробежного насоса (УЭЦН) с использованием данных, регулярно собираемых в корпоративных базах данных (БД): конструкция скважины, телеметрия с УЭЦН, данные с манометров и термометров, доступные замеры дебитов по фазам на АГЗУ (редкие замеры для калибровки). В предложенной модели анализируется электрическая составляющая работы УЭЦН, что позволяет оценить динамику коэффициента деградации характеристик установки и дебита газожидкостной смеси в насосе. Алгоритм апробирован на нескольких месторождениях компании, в статье приводится детальный разбор одной из скважин, начиная с фильтрации входных данных до восстановления динамики изменения дебита, а также сводная таблица с результатами апробирования на нескольких десятках скважин различных месторождений. Основным результатом проделанной работы является подтверждение возможности увеличения частотности замеров дебита за счет косвенных параметров, а также внедрение алгоритма в информационные системы компании, которые дают возможность осуществить мониторинг большого фонда скважин.

Ключевые слова: виртуальная расходомерия, моделирование многофазных течений, моделирование УЭЦН, мониторинг добычи нефти и газа

VERTUAL METERING AS A TOOL FOR ESP-EQUIPPED WELLS MONITORING

A.M. Andrianova¹, A.A. Loginov¹, R.A. Khabibullin¹, O.S. Kobzar²

¹ Gazpromneft NTC LLC, RF, Saint-Petersburg, ² MIPT Center for Engineering and Technology

This paper describes an approach to creating a virtual flow metering system (VFM). Proposed method is based on electric submersible pump system's monitoring. Whole VFM market was analyzed with taking method's relevance, possible and real industry applications into consideration. Created algorithm uses data that is regularly collected from oilfields and stored in corporate's databases. Mainly used parameters are well's construction, telemetry data from ESP system, pressure and temperature from different parts of the well, and available oil production data, divided by phases, that is obtained rarely and used for calibration. Suggested solution considers electric part of an ESP system and so it reveals possibility to estimate ESP degradation dynamics for liquid-gas mixture production restoring by using correction coefficients. Presented algorithm was tested on the Company's oilfield. One well is shown as an example of method's work, including all steps from data preprocessing to liquid production dynamics recovering. Also results of algorithm usage on several dozen wells on various oilfields are presented. As one of the main results approving the possibility to increase liquid production measurements frequency should be mentioned. Such possibility is based on using indirect operating parameters and recovering dynamics of model's inner coefficients (e.g., ESP degradation), that make possible to estimate effectiveness of pump exploitation and possible optimization necessity. As another important result implementing of the algorithm into Company's IT systems should be mentioned. Such implementation reveals possibility for monitoring a big amount of wells in fast and effective way.

Keywords: virtual flow metering, multiphase flow modeling and estimation, ESP system modeling, oil and gas production monitoring

DOI: 10.7868/S2587739920040114

ВВЕДЕНИЕ

Установки электрических центробежных насосов (УЭЦН) – основной способ эксплуатации нефтяных месторождений как в «Газпром нефть», так и во многих других компаниях. Многие современные системы УЭЦН оснащены различными системами контроля и мониторинга. Среди них станции управления

с контроллерами, способными считывать и хранить данные погружной телеметрии и информацию о потреблении электроэнергии, автоматизированные системы контроля давления и температуры на устье скважины, а также на линейных и площадных объектах месторождения. Современные системы способны считывать и хранить значения параметров с частотой раз в секунду и даже чаще. Высокая частота сбора