

DOI: <https://doi.org/10.25689/NP.2024.4.217-232>

EDN TLKBPJ

УДК 004.896:622.276.1/4

**Перспективы применения машинного обучения и нейронных сетей для прогнозирования успешности мероприятий по переводу и приобщению нефтяных пластов**

*Зольников Д.Н.*

*ООО «Тюменский нефтяной научный центр», Тюмень, Россия*

*ФГБОУ ВО «Тюменский индустриальный университет», Тюмень, Россия*

**Prospects for the use of machine learning and neural networks to predict the success of oil reservoir transfer and integration activities**

*D.N. Zolnikov*

*Tyumen Oil Research Center LLC, Tyumen, Russia*

*Industrial University of Tyumen, Tyumen, Russia*

**E-mail: DN\_Zolnikov2@tnnc.rosneft.ru**

**Аннотация.** В статье рассматривается подход к повышению успешности мероприятий по переводу и приобщению нефтяных пластов – посредством применения машинного обучения и нейронных сетей. В настоящее время успешность мероприятий по объекту исследования оставляет 50–60 %. В ходе геолого-промыслового анализа было выделено 65 параметров, влияющих на эффективность проведения мероприятий. Обучающая выборка включала 880 фактически проведенных мероприятий по переводу и приобщению пластов. Наиболее точным инструментом для прогнозирования успешности мероприятий оказалась нейросетевая модель – точность прогнозирования на выборке валидации составила более 80 %. Тестирование модели было проведено на отдельной выборке, включающей 50 мероприятий по переводу и приобщению пластов за 2023 г. По результатам прогнозирования 41 из 50 прогнозов оказались верными, что составляет 82 %. Прирост в дополнительной добыче нефти по скважинам тестового набора возможен на 33,9 %. Данный подход позволит повысить точность успешных прогнозов по мероприятиям на 20-30 % по сравнению с существующим подходом, что способствует

сокращению числа неуспешных мероприятий и увеличению дополнительной добычи нефти.

**Ключевые слова:** перевод и приобщение, нефтяной пласт, прогнозирование, нейронная сеть, машинное обучение

**Для цитирования:** Зольников Д.Н. Перспективы применения машинного обучения и нейронных сетей для прогнозирования успешности мероприятий по переводу и приобщению нефтяных пластов // Нефтяная провинция.-2024.-№4(40).-С. 217-232. - DOI <https://doi.org/10.25689/NP.2024.4>. 217-232. - EDN TLKBPJ

**Abstract.** The article considers an approach to increasing the success of oil reservoir transfer and integration activities through the use of machine learning and neural networks. Currently, the success rate of activities on the object of research leaves 50-60 %. During the geological and commercial analysis, 65 parameters were identified that affect the effectiveness of the activities. The training sample included 880 actual activities carried out for the translation and introduction of layers. The neural network model turned out to be the most accurate tool for predicting the success of events – the accuracy of forecasting on the validation sample was more than 80 %. The model was tested on a separate sample, including 50 activities for the transfer and incorporation of layers in 2023. According to the forecast results, 41 out of 50 forecasts turned out to be correct, which is 82 %. An increase in additional oil production from the wells of the test set is possible by 33,9 %. This approach will increase the accuracy of successful forecasts for events by 20-30 % compared to the existing approach, which helps to reduce the number of unsuccessful events and increase additional oil production.

**Key words:** translation and communication, oil reservoir, forecasting, neural network, machine learning

**For citation:** D.N. Zolnikov Perspektivy primeneniya mashinnogo obucheniya i neyronnykh setey dlya prognozirovaniya uspezhnosti meropriyatiy po perevodu i priobshcheniyu neftyanykh plastov [Prospects for the use of machine learning and neural networks to predict the success of oil reservoir transfer and integration activities]. Neftyanaya Provintsiya, No. 4(40), 2024. pp. 217-232. DOI <https://doi.org/10.25689/NP.2024.4>. 217-232. EDN TLKBPJ (in Russian)

## Введение

Перевод и приобщение (ПиП) нефтяных пластов – разновидность геолого-технических мероприятий, заключающаяся в создании дополнительных фильтрационных каналов между стволом скважины и нефтяными пластами с отключением или сохранением предыдущих перфораций.

Мероприятия проводят снизу вверх или наоборот. Перед ПиП проводят геолого-промысловые исследования для изучения нефтенасыщенности продуктивных пластов.

Рассматриваемое месторождение является многопластовым с этажом нефтегазоносности около 2 км. За последние годы наблюдается отклонение в -21,8 % в дополнительной добыче нефти от проведенных ПиП, при этом, общее количество проведенных мероприятий превышает плановые показатели. Основная причина отклонения в дополнительной добыче нефти связана с большим числом неуспешных мероприятий, доля которых составляет около 40-50 %.

В настоящее время скважины-кандидаты для геолого-технических мероприятий (ГТМ) ранжируются посредством геолого-промыслового анализа [1-4] в зонах локализации остаточных извлекаемых запасов нефти (ОИЗН). В условиях зрелого месторождения корректно оценить зоны локализации ОИЗН является нетривиальной задачей в связи с наличием значительных геолого-промысловых неопределенностей, возникающих в процессе длительной разработки.

Поэтому для повышения эффективности ГТМ целесообразно применять многокритериальный анализ, учитывающий большое количество факторов. Недостатком такого подхода является сложность в корректном определении функциональной зависимости между параметрами, влияющими на успешность мероприятий по ПиП, которые сложно выделить при ручном анализе.

В данной работе с целью повышения успешности мероприятий по ПиП предлагается использование машинного обучения и нейронных сетей.

### **Описание объекта исследования**

Рассматриваемое месторождение в настоящее время находится на завершающей стадии разработки, запасы высокопродуктивных

эксплуатационных объектов практически выработаны, дальнейшие перспективы связаны с эффективной разработкой объектов в зонах ОИЗН, а также довыработкой запасов из низкопроницаемых пачек.

Объектом исследования является один из основных нефтяных продуктивных пластов рассматриваемого зрелого месторождения, включающий 4 пачки. Пачки характеризуются разными фильтрационно-емкостными свойствами и, как следствие, разной степенью выработки запасов. На данный объект приходится основная доля мероприятий по ПиП, проведение которых продолжается и в настоящее время.

### **Формирование обучающей выборки**

В ходе геолого-промыслового анализа было выделено 65 параметров, которые вошли в обучающую выборку, включающую информацию по целевым скважинам и скважинам окружения (фильтрационно-емкостные свойства, энергетическое состояние, добыча жидкости, нефти, закачка воды, количество скважин окружения, расстояние до ближайшей нагнетательной скважины и др.). Пример данных обучающей выборки с 20 наиболее влияющими параметрами на успешность ПиП приведен в табл. 1. Определение степени влияния параметров на успешность мероприятий будет рассмотрено далее по ходу работы. В обучающую выборку вошли и другие параметры, однако их влияние было меньше.

Таблица 1

*Пример данных обучающей выборки  
(20 наиболее влияющих параметров на успешность ПиП)*

Параметры обучающей выборки	Номер скважины		
	W1	W2	W3
Номер пачки	1	2	2
Запускная обводненность по целевой скважине с карты на дату ПиП, %	97,7	98,7	93,6
Текущие извлекаемые запасы (ТИЗ) нефти по целевой скважине с карты на дату ПИП, тыс. т.	0,6	3,7	5,7

Суммарная накопленная добыча жидкости по окружающим скважинам на дату ПиП, тыс. т.	1750	17895	17831
Средняя проницаемость по геофизическим исследованиям (ГИС) окружающих скважин, мД	459	977	1442
Коэффициент продуктивности по целевой скважине с карты на дату ПиП, м <sup>3</sup> /сут/атм	12,21	5,29	15,37
Среднее забойное давление окружающих действующих нагнетательных скважин на дату ПиП, атм	253,2	271,4	273,3
Средний Kh по пачкам окружающих скважин, мД*м	711	1052	1311
Пластовое давление по целевой скважине с карты на дату ПиП, атм	151	155	148,8
Суммарная накопленная добыча нефти по окружающим скважинам на дату ПиП, тыс. т.	87	1837	846
Расстояние от целевой скважины до ближайшей нагнетательной скважины с накопленной закачкой более 500 тыс. м <sup>3</sup> , м	376,2	451,5	511,1
Средние ГИЗ по скважинам окружения с карты на дату ПиП, тыс.т.	2,1	1,4	2,9
Средний запускной дебит нефти по окружающим новым скважинам с 2014 г., т/сут	6,5	14,5	16,4
Суммарная накопленная закачка по окружающим скважинам на дату ПиП, тыс.т,	5140	13289	3402
Коэффициент проницаемости по ГИС целевой скважины, мД	433,9	1600,9	396,7
Средняя обводненность по окружающим скважинам на дату ПиП, %	99	96,6	97,4
Расстояние от целевой скважины до ближайшей действующей нагнетательной скважины, м	376,2	451,5	718,6
Средняя запускная обводненность по окружающим новым скважинам с 2014 г, %	98,1	95,8	89,6
Расстояние от целевой скважины до ближайшей действующей добывающей скважины, м	169	152	147
Количество действующих окружающих нагнетательных скважин, шт.	3	3	1
Успешность ПиП (целевой параметр – 0 или 1)	1	0	1
Накопленная добыча нефти по целевой скважине за первый год после ПиП, тыс.т. (не участвует в прогнозе)	1,6	0,1	3,6

В обучающую выборку вошло 880 мероприятий по ПиП по 734 скважинам и по 3 пачкам объекта. Была произведена очистка обучающей выборки от возможных выбросов для повышения прогностической

способности. Выбросы представляли собой такие значения, которые существенно отличались от основного набора данных. Выбросы могли возникнуть в результате случайных ошибок при изменениях или обработках данных, их присутствие в обучающей выборке могло негативно повлиять на конечный результат прогнозирования.

В последующем данные были нормализованы – приведены к единому максимальному значению (единице) с целью устранения дисбаланса в масштабе различных признаков. Это необходимо для того, чтобы параметры с более высокими значениями не оказывали максимального влияния на процесс обучения модели.

Целевым параметром для прогнозирования была выбрана успешность мероприятий по ПиП. Успешность мероприятий выбиралась из условия достижения требуемой добычи нефти за первый год после ПиП и в виду экономических ограничений был установлен минимальный порог в 0,5 тыс.т. То есть если за первый год после ПиП накопленная добыча нефти по скважине оказывалась меньше 0,5 тыс. т, мероприятие по ПиП считалось неуспешным и целевой параметр принимал значение 0, иначе значение 1.

### **Выбор метода прогнозирования**

Для прогнозирования успешности ПиП было рассмотрено пять распространенных методов классификации машинного обучения (случайный лес, градиентный бустинг, метод k-ближайших соседей, логическая регрессия, метод опорных векторов) и один метод нейронной сети с функцией потерь классификации (многослойный персептрон).

Метод случайного леса был выбран ввиду его устойчивости к выбросам и способности справляться с большим количеством признаков без риска переобучения. Он обеспечивает высокую точность за счет создания ансамбля деревьев решений, что делает его подходящим для сложных многомерных данных.

Градиентный бустинг был рассмотрен из-за его способности эффективно улучшать качество предсказаний за счет последовательного обучения слабых моделей, что позволит повысить общую точность прогнозирования. Преимущество заключается в достижении высокой точности при работе с нелинейными зависимостями.

Метод k-ближайших соседей был использован как базовый алгоритм, позволяющий оценить качество классификации при минимальной сложности модели. Он эффективен на небольших наборах данных, однако его производительность может снижаться при большом числе признаков и выборок.

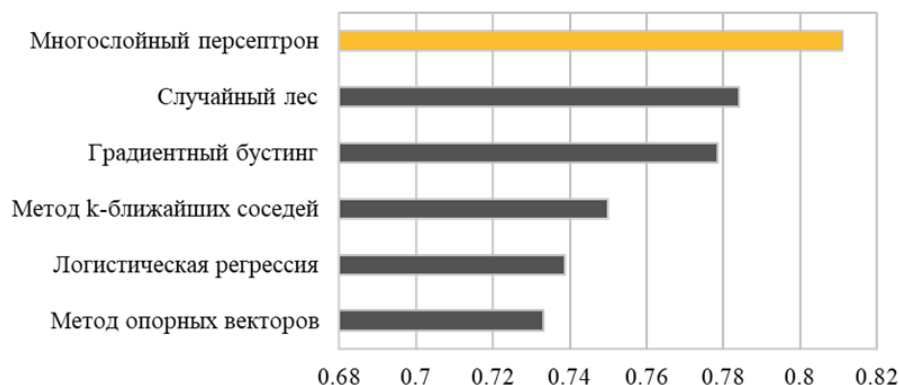
Логистическая регрессия была выбрана за ее простоту и способность интерпретировать результаты. Она хорошо справляется с линейно разделимыми данными и является стандартным методом для бинарной классификации.

Метод опорных векторов был применен из-за его способности находить оптимальные разделяющие гиперплоскости в высокоразмерных данных. Благодаря использованию ядерных функций, этот метод особенно полезен для работы с нелинейными зависимостями и часто обеспечивает высокую точность классификации [5].

Многослойный персептрон был рассмотрен из-за его способности эффективно моделировать сложные нелинейные зависимости в данных. Этот метод нейронной сети может адаптироваться к различным типам данных за счет настройки многослойной архитектуры, что делает его подходящим для решения задач классификации с большим количеством признаков [6].

На основе обучающей выборки были созданы модели машинного обучения, нейронной сети и оценены их прогностические способности на основе коэффициента детерминации (корреляции)  $R^2$ . Наибольшую точность показал метод многослойный персептрон (Рис. 1). Далее по ходу работы

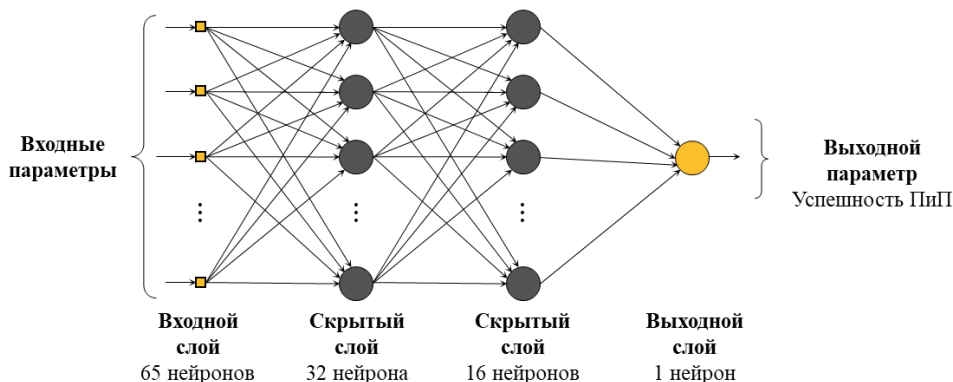
будет рассмотрено прогнозирование успешности мероприятий по ПиП посредством нейросетевой модели в виду наибольшей точности прогноза.



*Рис. 1. Распределение коэффициента детерминации  $R^2$  по методам прогнозирования*

### Архитектура нейронной сети

Полносвязанная нейронная сеть была построена с использованием языка программирования Python и библиотеки TensorFlow Keras (Рис. 2). В данной архитектуре каждый нейрон предыдущего слоя соединен с каждым нейроном последующего слоя, что обеспечивает полную передачу информации между слоями. Для оптимизации параметров модели был применен алгоритм Adam, а в качестве функции потерь выбрана бинарная кросс-энтропия (Binary Crossentropy). В промежуточных слоях использовалась функция активации ReLU, а на выходном слое – функция активации Sigmoid.



*Рис. 2. Схема построенной нейронной сети*



Алгоритм оптимизации представляет собой метод нахождения оптимальных параметров модели с целью минимизации функции потерь. Функция активации вводит нелинейность в модель, позволяя ей решать более сложные задачи, чем те, которые можно решить с использованием исключительно линейных преобразований. Функция ReLU возвращает входное значение, если оно больше нуля, и устанавливает его равным нулю в противном случае, что эффективно справляется с проблемой затухающих градиентов. Функция Sigmoid нормализует входные данные в диапазоне от 0 до 1, что особенно полезно для задач классификации, где требуется интерпретация выхода как вероятности принадлежности к одному из классов.

Для улучшения качества модели и предотвращения переобучения были внедрены методы регуляризации, такие как Dropout,  $L_1$  и  $L_2$ . Алгоритм Dropout случайным образом отключает часть нейронов во время обучения, что способствует обучению модели на более общих признаках, снижая риск переобучения. Регуляризация  $L_1$  используется для уменьшения сложности модели и отбора наиболее значимых признаков, тогда как  $L_2$  предотвращает чрезмерное увеличение весов, что также помогает избежать переобучения.

Нейронная сеть включала четыре слоя: входной, два скрытых и выходной. Архитектура модели была выбрана на основе критерия – максимальной точности прогнозирования.

На входной слой поступали геолого-промысловые параметры, количество нейронов на данном слое соответствовало числу этих параметров. Каждый нейрон входного слоя принимал отдельное значение параметра, передавая его на следующие слои.

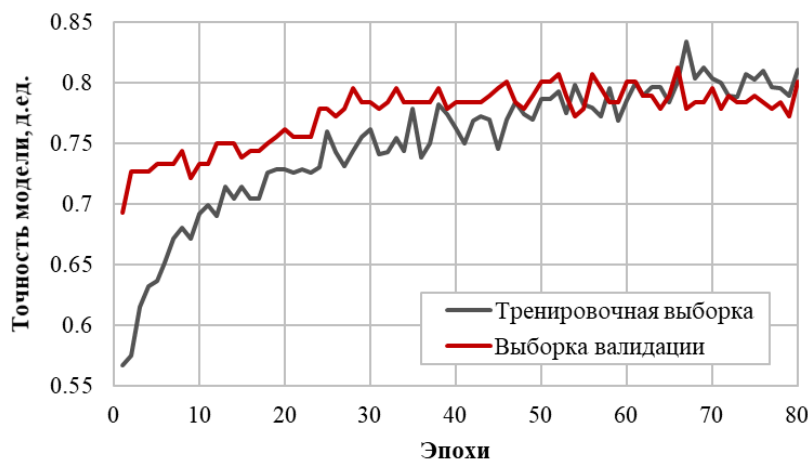
Скрытые слои выполняют важную роль в нейронной сети, поскольку они отвечают за выявление сложных взаимосвязей между входными данными. В отличие от входного и выходного слоев, скрытые слои не взаимодействуют напрямую с внешними данными или целевыми значениями, а их основная функция заключается в преобразовании входных данных на

разных стадиях обработки. На этих слоях с помощью функции активации происходит нелинейная трансформация данных, что позволяет нейронной сети решать задачи, которые не поддаются линейным методам. Скрытые слои постепенно выделяют и усиливают значимые признаки, что улучшает способность модели к прогнозированию.

На выходном слое генерировалось некоторое числовое значение в диапазоне от 0 до 1, которое интерпретировалось как вероятность успешности проведения мероприятий по ПиП. Если итоговое значение находилось в диапазоне от 0,5 до 1, мероприятие считалось успешным, значения ниже 0,5 указывали на неуспешный результат.

### Обучение нейронной сети

Обучающий набор данных был разделен в пропорции 80 % на тренировочную выборку и 20 % на выборку валидации. Тренировочная выборка содержала данные для обучения модели, выборка валидации использовалась для оценки её качества на промежуточных этапах обучения и для настройки гиперпараметров, таких как количество скрытых слоев, нейронов, эпох обучения, алгоритмов регуляризации и функций активации. Процесс обучения модели представлен на рис. 3. Точность являлась основной метрикой для оценки качества модели, особенно в контексте задач классификации, где важно определить долю правильно предсказанных значений.



*Рис. 3. Распределение точности нейросетевой модели в процессе обучения*

На начальных этапах обучения точность на тренировочной выборке была ниже, чем на валидационной, что связано с тем, что модель ещё не успела выучить достаточные закономерности в данных. По мере увеличения числа эпох обучения модель улучшала свою прогностическую способность на тренировочных данных, и точность на тренировочной выборке достигла точности на выборке валидации. Завершение обучения было зафиксировано на этапе, когда дальнейшее повышение точности на тренировочной выборке при стабилизации точности на валидации сигнализировало о риске переобучения.

Общее количество эпох обучения было выбрано с целью предотвращения переобучения. Эпоха представляет собой один полный цикл обучения, в ходе которого модель проходит через весь обучающий набор данных. Для данной модели было проведено 80 эпох обучения. После этого этапа наблюдалось расхождение показателей точности: точность на тренировочной выборке продолжала расти, точность на выборке валидации стабилизировалась. Такой тренд свидетельствует о начале процесса переобучения, когда модель начинает подстраиваться под специфические данные тренировочной выборки, теряя способность к обобщению на новых данных.

### **Распределение влияющих параметров**

В ходе исследования нейронной сети были проанализированы весовые коэффициенты каждого признака, снятые с входного слоя модели. На основе этих значений был проведён ранжированный анализ, в ходе которого признаки были упорядочены от наиболее значимых к менее значимым (Рис. 4). Наибольшее влияние на успешность мероприятий по ПиП в процессе настройки нейронной сети оказали следующие параметры: номер пачки, запускная обводненность по целевой скважине (определённая с карты обводненности для всех скважин, исключая целевые), а также

текущие извлекаемые запасы нефти (ОИЗН) по целевой скважине, основанные на карте плотности подвижных запасов нефти.



**Рис. 4. Распределение важности первых двадцати параметров на успешность ПИП**

Стоит отметить, что влияющие параметры могут отличаться в зависимости от подаваемой обучающей выборки. Однако не стоит ориентироваться на один влияющий параметр, более коррелируемый с целевым. Успешность мероприятий по ПИП зависит от многих факторов, и нельзя выделить один единственный, например, текущие ОИЗН. Зачастую карты текущих ОИЗН могут не подтверждаться за счет длительной истории, а также одновременной эксплуатации скважинами нескольких объектов. Поэтому

требуется учесть все параметры и тогда успешность от мероприятий будет значительно выше, чем если только ориентироваться на карты текущих ОИЗН.

### Тестирование модели нейронной сети

Для финальной оценки работы нейронной сети была использована тестовая выборка, применённая после завершения обучения модели. Эта выборка представляла собой независимый набор 50 мероприятий по ПиП, проведенным за предыдущий 2023 г. Данные тестовой выборки не использовались в процессе обучения и служили для проверки прогностической способности модели на новых данных.

По результатам прогнозирования, модель дала верный прогноз для 41 из 50 мероприятий, что составляет 82 % точности (Рис. 5). Из 27 успешных фактических мероприятий нейросетевая модель корректно предсказала успешность (верный прогноз), однако 4 успешных мероприятия были классифицированы как неуспешные (неверный прогноз). Кроме того, 14 неуспешных мероприятий были правильно предсказаны как неуспешные, тогда как 5 неуспешных мероприятий были ошибочно предсказаны как успешные.

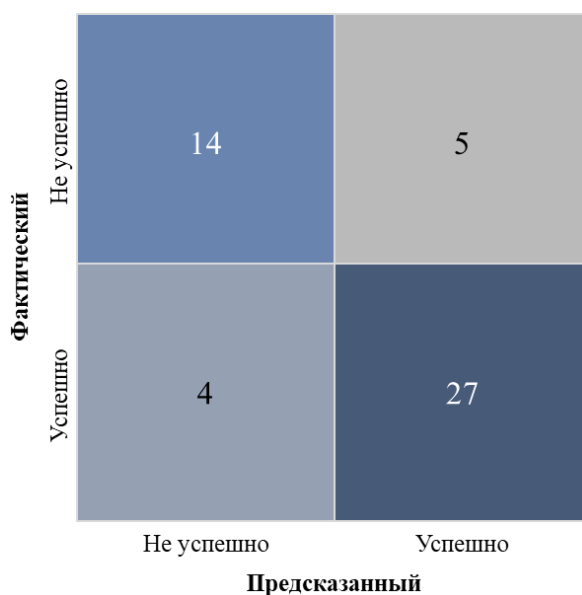


Рис. 5. Матрица ошибок классификации

Отклонение прогнозов от фактических результатов может быть связано с ограниченностью обучающей выборки, а также сложностью и неоднородностью входных данных. Для повышения точности модели целесообразно расширить обучающую выборку и искать дополнительные параметры, которые наиболее коррелируют с целевой переменной. Дополнительно повысить точность модели можно за счет снижения слабо влияющих параметров, однако это повлияет незначительно.

Средняя дополнительная добыча нефти по одному успешному мероприятию из вышеописанных 50 фактически проведенных ПиП составила 2,4 тыс.т. В рассмотренном случае пересмотреть решение о проведении ПиП можно было в 14 скважинах, взяв другие скважины-кандидаты. Учитывая точность модели в 80 %, можно было получить 11 успешных ПиП с дополнительной добычей 26,4 тыс.т или +33,9 % к накопленной добыче нефти по всем скважинам.

## **Выводы**

Проведен геолого-промысловый анализ по объекту исследования с выделением 65 параметров, влияющих на успешность мероприятий по ПиП. Была сформирована обучающая выборка объемом 880 мероприятий, за исключением данных, являющихся выбросами.

Были построены пять моделей машинного обучения (случайный лес, градиентный бустинг, метод k-ближайших соседей, логическая регрессия, метод опорных векторов) и одна модель нейронной сети (многослойный персептрон). Наибольшую прогностическую способность показал метод многослойный персептрон, точность на выборке валидации составила более 80 %.

Было произведено тестирование нейросетевой модели на выборке, включающей 50 различных мероприятий по ПиП по объекту исследования. В ходе тестирования точность прогноза составила 82 % (41 из 50 прогнозов

были верными). Прирост в дополнительной добыче нефти по скважинам тестового набора возможен на 33,9 %.

Применение искусственного интеллекта (машинного обучения, нейронных сетей) показало высокую эффективность при прогнозировании успешности мероприятий по ПиП.

Данный подход позволит повысить точность прогнозов успешных мероприятий по ПиП с 50-60 % до 80 %, что составляет около 20-30 %. Это позволит получить значительный прирост в дополнительной добыче нефти за счет других успешных мероприятий или сократить затраты по непроведенным ПиП. К тому же данный подход является менее трудозатратным по сравнению с традиционным ручным методом подбора, что позволит рассмотреть большее количество скважин и выявить наиболее успешных для проведения мероприятий. Таким образом, перспективы применения методов машинного обучения и нейронной сети для прогнозирования успешности есть, а именно – сокращение числа неуспешных мероприятий, увеличение дополнительной добычи нефти.

#### Список литературы

1. Разработка алгоритмов автоматизированного подбора геолого-технических мероприятий и критериев ранжирования скважин-кандидатов на основе нечетких множеств / А.Е. Алтунин [и др.]// Нефтяное хозяйство. 2016. № 9. С. 94-99.
2. Тимонов А.В. Системный подход к выбору геолого-технических мероприятий для регулирования разработки нефтяных месторождений: дис. ...канд. техн. наук: 25.00.17. – Уфа., 2010. – 151 с.
3. Колтун А.А. Оценка эффективности и оптимальное планирование геолого-технических мероприятий на нефтяных месторождениях дис. ...канд. техн. наук: 05.13.01. – Москва, 2005. – 112 с.
4. Григорьева М.П. Геологическое обоснование выбора скважин для перевода на недоизученные пласты на примере Фаинского месторождения // Научно-технический вестник ОАО «НК «РОСНЕФТЬ»». 2012. № 1. С. 7-9.
5. Лимановская О.В. Основы машинного обучения: учебное пособие. Министерство науки и высшего образования РФ – Екатеринбург: Издательство Уральского университета, 2020. – 88 с.
6. Шолле Ф. Глубокое обучение на Python. 2-е межд. издание: учебное пособие. СПб.: Питер, 2023. – 576 с.



### References

1. Development of algorithms for automated selection of geological and technical measures and criteria for ranking candidate wells based on fuzzy sets / A.E. Altunin [et al.]// Oil industry. 2016. No. 9. pp. 94-99. (in Russian)
2. Timonov A.V. A systematic approach to the selection of geological and technical measures to regulate the development of oil fields: dis. ...candidate of Technical Sciences: 25.00.17. – Ufa., 2010. – 151 p. (in Russian)
3. Koltun A.A. Efficiency assessment and optimal planning of geological and technical measures at oil fields of dis. ...candidate of Technical Sciences: 05.13.01. – Moscow, 2005. – 112 p. (in Russian)
4. Grigorieva M.P. Geological justification of the choice of wells for transfer to unexplored formations on the example of the Fainskoye field // Scientific and Technical Bulletin of JSC NK ROSNEFT. 2012. No. 1. pp. 7-9. (in Russian)
5. Limanovskaya O.V. Fundamentals of machine learning: a textbook. Ministry of Science and Higher Education of the Russian Federation – Yekaterinburg: Ural University Press, 2020. – 88 p. (in Russian)
6. Scholle F. Deep learning in Python. 2nd intern. edition: textbook. St. Petersburg: St. Petersburg, 2023. – 576 p. (in Russian)

### Сведения об авторах

*Зольников Даниил Николаевич*, ведущий специалист УГРМ Самотлорнефтегаз, ООО «Тюменский нефтяной научный центр», ФГБОУ ВО «Тюменский индустриальный университет»

Россия, 625048, Тюмень, ул. Максима Горького, 42

E-mail: DN\_Zolnikov2@tnnc.rosneft.ru

### Authors

*D.N. Zolnikov*, leading specialist URRM Samotlorneftegaz, Tyumen Oil Research Center LLC, Industrial University of Tyumen

42, Maxim Gorky Str., Tyumen, 625048, Russian Federation

E-mail: DN\_Zolnikov2@tnnc.rosneft.ru

*Статья поступила в редакцию 21.09.2024*

*Принята к публикации 17.12.2024*

*Опубликована 30.12.2024*