ДОКЛАД

Применение машинного обучения для обоснования параметров трещин авто-ГРП в задачах адаптации ГДМ

Арман Казарян

Искусственный интеллект в нефтегазовой отрасли

ТИНГ Тюменский институт нефти и газа

Машинное обучение | LSTM-прогноз | Градиентный спуск | Автоадаптация ГДМ | Прокси-модель | Авто-ГРП

Влияние трещин авто-ГРП на разработку

Теория

Развитие трещины авто-ГРП на горизонтальных скважинах.
Горизонтальное сечение области развития трещины авто-ГРП:

До прорыва трещины авто-ГРП

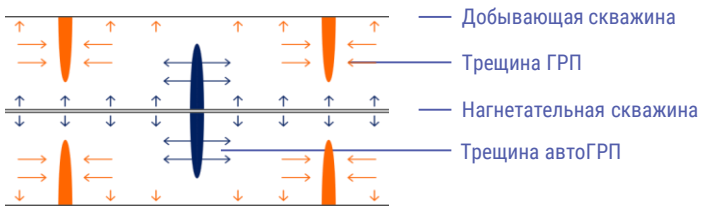

После прорыва трещины авто-ГРП

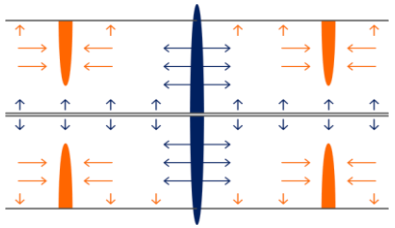

Факт

Фактический пример развития трещины авто-ГРП по данным микросейсмики

Условные обозначения

- Основные траектории развития техногенных трещин
- Второстепенные траектории развития техногенных трещин
- Зона развития техногенной трещиноватости

Амплитуда

0 — 100

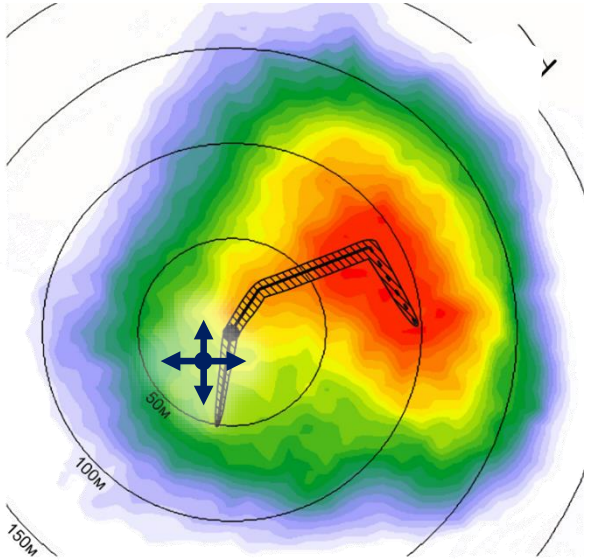

Исследование процесса авто-ГРП

Отмечается **эффект гистерезиса** для трещин авто-ГРП при раскрытии и смыкании

По результатам интерпретации ГДИ на скважине полудлина трещины авто-ГРП не превышает 540 м и в среднем составляет **156 м**

При пролонгации длин трещин **до значений давлений нагнетания** в исторический максимум закачки средняя полудлина составит **750 м**

Характерный вид ГДИ, свидетельствующий о наличии авто-ГРП

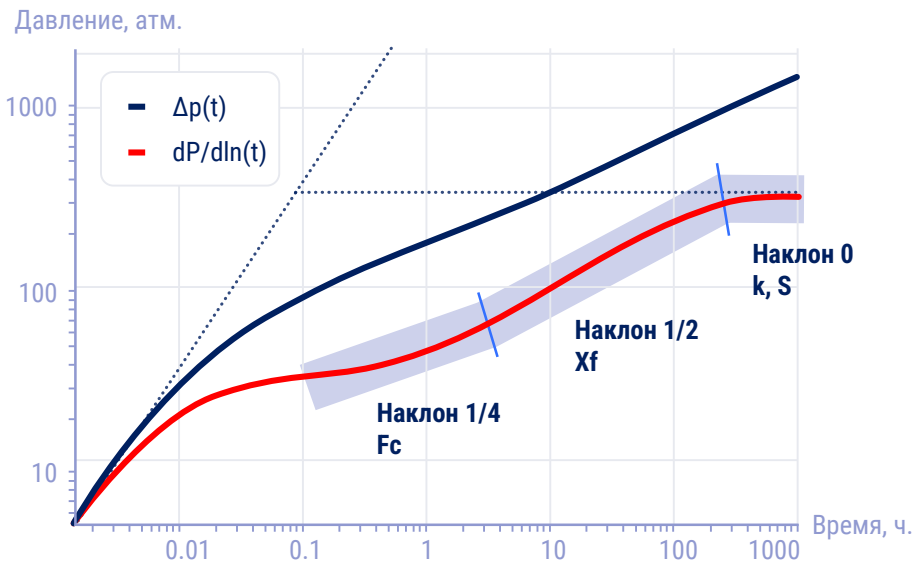

Зависимость полудлины трещины от ΔP

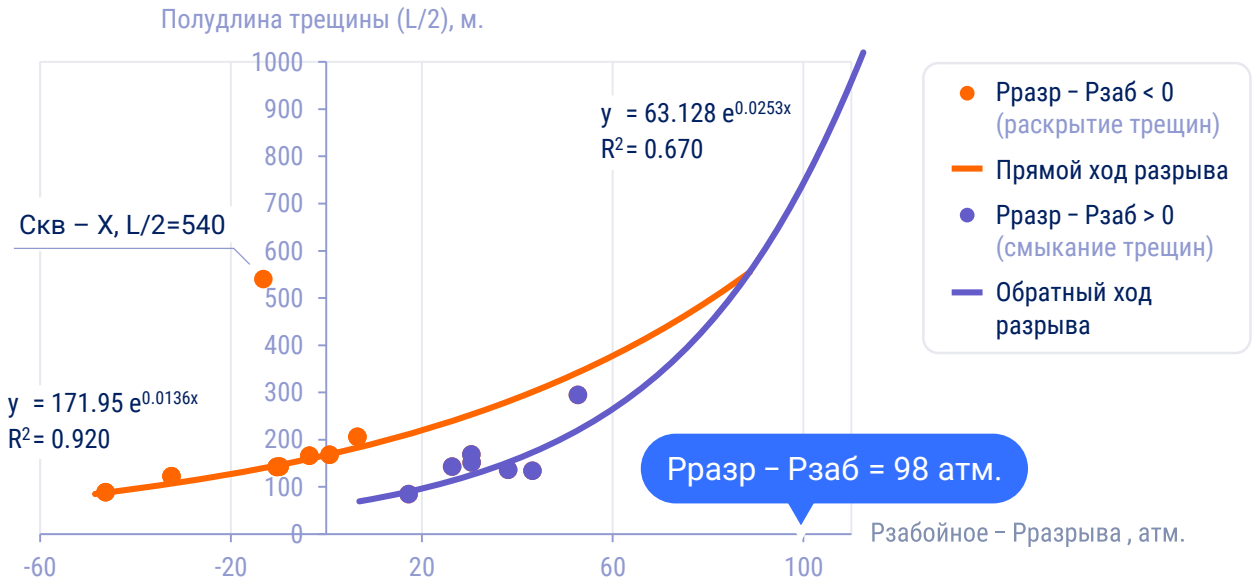

Виды трещин авто-ГРП

Влияние авто-ГРП на адаптацию ГДМ

Классические представления

Одинаковые длины, раскрытость и проводимость в двух противоположных направлениях

Альтернативные варианты

развития техногенных трещин

Неравноплечее развитие

Образование звездчатой структуры

Структура с низкой степенью фрактальности

Структура с высокой степенью фрактальности

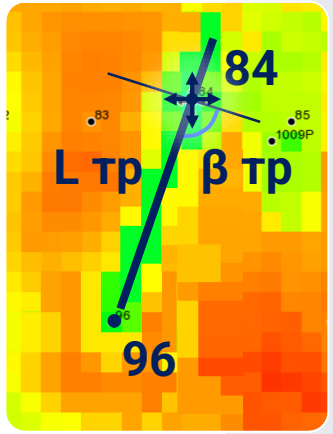

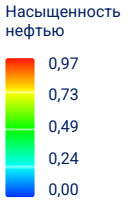

Обводненность скважины №96, %

Без учёта трещин авто-ГРП адаптация **практически невозможна**

Цель и задачи работы

Применить методы машинного обучения для подбора параметров трещин авто-ГРП с целью сокращения времени автоадаптации ГДМ

01 **Подготовка данных** для обучения нейронной сети

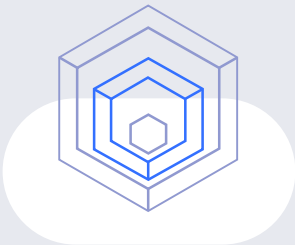

02 **Выбор и обучение нейросети** для прогнозирования промысловых показателей по параметрам авто-ГРП

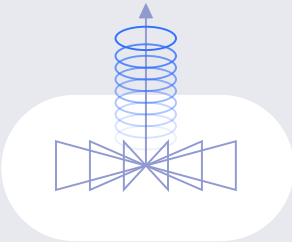

03 **Решение оптимизационной задачи** — подбор параметров трещин авто-ГРП для соответствия расчётной добычи нефти историческим

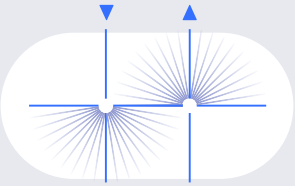

04 **Сопоставление результатов** гидродинамических расчётов и расчётов, полученных с помощью машинного обучения

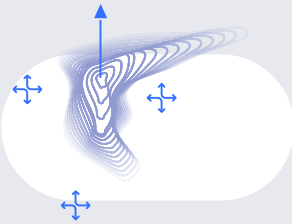

Концепция

Традиционный метод адаптации ГДМ

Эксперт-гидродинамик
Расчёты фильтрационной модели

Исходные данные (гидродинамическая модель)

Расчёт фильтрационной модели

Модель адаптирована? ?

нет

да

Успех

Предложенный метод

Корректировка параметров методами **машинного обучения**

Исходные данные (гидродинамическая модель)

Многовариантные расчёты фильтрационных моделей

Обучение нейронной сети (НС)

Настройка гиперпараметров

НС обучилась? ?

нет

да

Подбор параметров на прокси-модели

Подготовка данных

ШАГ

1

Выбор источника данных

Секторная модель реального месторождения

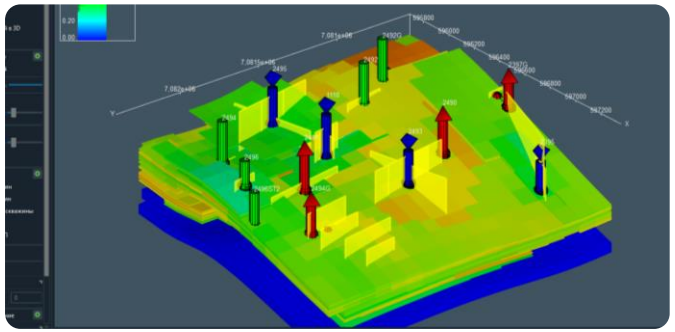

ШАГ

2

Задание варьируемых параметров

Варьируемые параметры трещины авто-ГРП

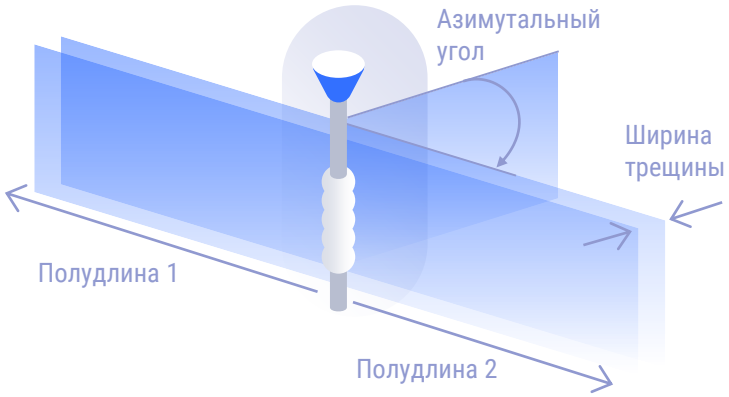

ШАГ

3

Запуск проекта «Автоадаптации»

для генерации выборки

Всего было рассчитано **300** вариантов адаптации
Время расчётов составило **трое суток**
Время расчёта одной модели **10-15 минут**

Задание варьируемых переменных

ШАГ

4

Результат сгенерированных вариантов адаптации

Для выборки использовались **первые 100 расчётов**

Id	Путь	Статус	Невязка по дебиту нефти	D1	D2
56	A001/e1_v00056	Рассчитана	3,54617	0,00345973	0,00523
55	A001/e1_v00055	Рассчитана	4,18144	0,00469354	0,00670
54	A001/e1_v00054	Рассчитана	3,49487	0,00536433	0,00521
53	A001/e1_v00053	Рассчитана	3,9605	0,00465226	0,00325
52	A001/e1_v00052	Рассчитана	3,92438	0,00435554	0,00275
51	A001/e1_v00051	Рассчитана	3,69902	0,00295603	0,00628
50	A001/e1_v00050	Рассчитана	4,94203	0,00359945	0,00609
49	A001/e1_v00049	Рассчитана	3,40962	0,00247198	0,00309
48	A001/e1_v00048	Рассчитана	4,07695	0,00313098	0,00488
47	A001/e1_v00047	Рассчитана	3,80664	0,00309956	0,00470
46	A001/e1_v00046	Рассчитана	3,41716	0,00308936	0,00363
45	A001/e1_v00045	Рассчитана	3,75801	0,00411896	0,0036
44	A001/e1_v00044	Рассчитана	4,00369	0,00545112	0,00426
43	A001/e1_v00043	Рассчитана	3,72604	0,00283532	0,00344
42	A001/e1_v00042	Рассчитана	3,52559	0,00274979	0,0041
41	A001/e1_v00041	Рассчитана	4,01104	0,00457194	0,0065

Выбор архитектуры и обучение нейронной сети

Принцип работы LSTM

1

«Forget gate layer»
«Слой фильтра забывания»

$$f^t = \sigma(W_f \cdot [h^{t-1}, x^t] + b_f)$$

$$C^t_{temp} = f^t * C^{t-1}$$

σ – сигмоидальная функция активации
$tanh$ – тангенциальная функция активации

f, i, o – вектора со значениями от 0 до 1

Обучаемые параметры:
W – веса связей, b – вектор смещения

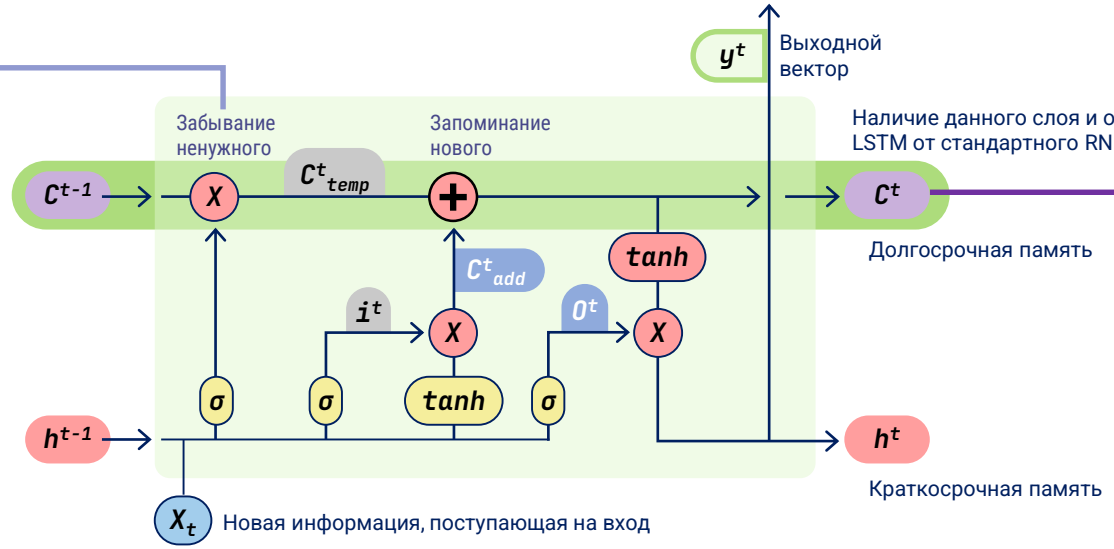

2

«Input layer gate»
«Слой входного фильтра»

$$i^t = \sigma(W_i \cdot [h^{t-1}, x^t] + b_i)$$

$$C^t_{add} = tanh(W_C \cdot [h^{t-1}, x^t] + b_C)$$

$$C^t = C^t_{temp} + i^t * C^t_{add}$$

3

Обновление h^t и получение выходного вектора y^t

$$o^t = \sigma(W_o \cdot [h^{t-1}, x^t] + b_o)$$

$$h^t = o^t * \tanh(C^t)$$

$$y^t = \sigma(W_y h^t + b_y)$$

Схема обучения

Все данные перед обучением нормированы путём Z-нормализации

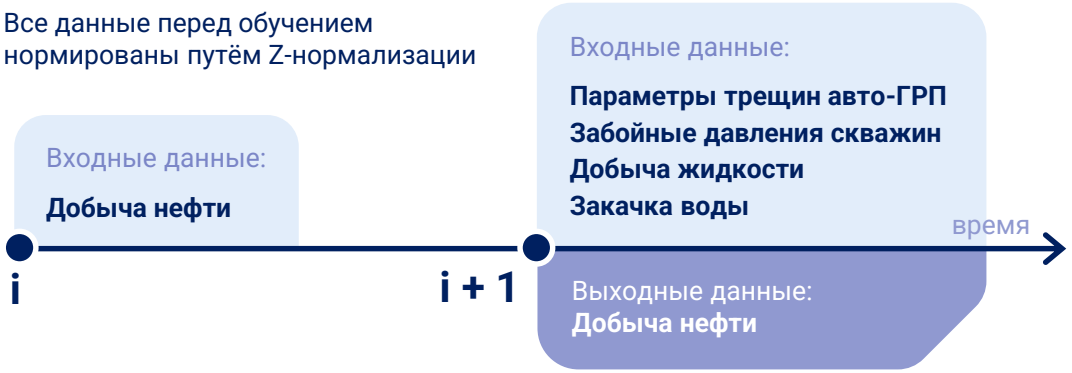

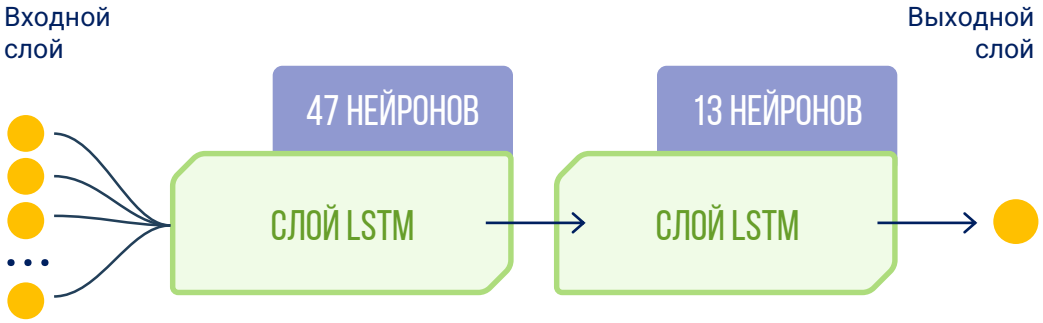

Обучающая выборка: модели 1-50
Тестовая выборка: модели 51-100

Метод минимизации ошибки

$$\mathrm{MSE} = \frac{1}{N}\sum_{i=1}^{N}(y_{pred_i} - y_{expec_i})^2$$

MSE	**Среднеквадратичная ошибка между расчётными и фактическими данными**
y_{pred_i}	Ожидаемое выходное значение
y_{expec_i}	Фактическое выходное значение обучаемой модели

$\overrightarrow{\theta_{k+1}} = \overrightarrow{\theta_k} - \alpha\nabla L(\overrightarrow{\theta_k})$ - Стандартный градиентный спуск, скорость обучения фиксирована

$g_t = \nabla f_t(\theta_{t-1})$

$m_t = \beta_1 * m_{t-1} + (1-\beta_1) * g_t$ - Momentum

$b_t = \beta_2 * b_{t-1} + (1-\beta_2) * g_t^2$ - RMSProp

$\hat{m}_t = \frac{m_t}{1-\beta_1^t}, \quad \hat{b}_t = \frac{b_t}{1-\beta_2^t}$ - Поправка на смещение

g_t	Градиент на временном интервале t
m_t	Экспоненциальная скользящая средняя для g_t
b_t	Экспоненциальная скользящая средняя для квадрата g_t
θ	Обновляемый параметр (веса связей)

Задаются стандартно по алгоритму Adam:

$\beta_1 = 0.9$	Скорость затухания импульса
$\beta_2 = 0.999$	Скорость затухания для квадратичных градиентов
$\varepsilon = 10^{-8}$	Малое значение, задаётся для предотвращения деления на ноль

Задаётся пользователем:

$\alpha = 10^{-3}$	Скорость обучения

Функцией оптимизации в данной работе служит оптимизатор **Adam**, в основе которого лежат методы градиентного спуска

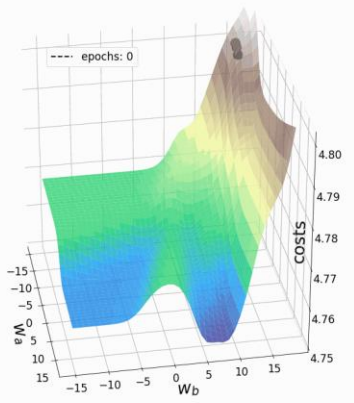

Конечная формула обновления параметров по Adam

$$\boldsymbol{\theta_t = \theta_{t-1} - \left(\frac{\alpha * \hat{m}_t}{\sqrt{\hat{b}_t + \varepsilon}}\right)}$$

Результаты обучения

Ошибка на обучающей выборке ~ 3%

Ошибка на тестовой выборке ~ 10%

График обучения

Пример прогнозирования добычи нефти на тестовом варианте №100 скв №1

RMSE, Прогноз 1	1.6847
RMSE, Прогноз 2	0.6636

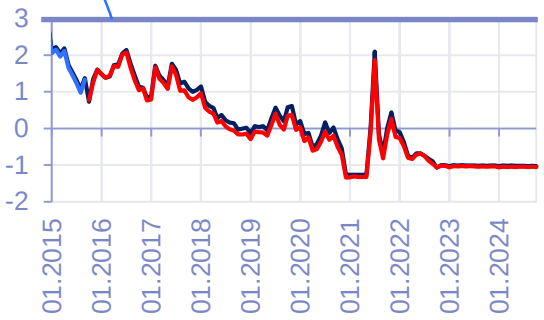

RMSE, Прогноз 1	0.0761
RMSE, Прогноз 2	0.1275

RMSE, Прогноз 1	0.0775
RMSE, Прогноз 2	0.1144

ГДМ

Прогноз 1 – **прогноз, выполненный на основе данных с предыдущего временного шага из ГДМ**

Прогноз 2 – **прогноз, выполненный на основе данных, полученных нейронной сетью за предыдущий временной шаг**

Модель ограничений и решение оптимизационной задачи (ОЗ)

На обученной нейронной сети, при фиксированных обученных параметрах (w, b) будет происходить **подбор параметров трещин** с целью минимизации невязки между расчётной и фактической добычей нефти по Adam (10 запусков оптимизации по 200 шагов обновления параметров трещин с разной начальной инициализацией) - сохраняем лучший вариант.

$$ЦФ = \frac{1}{N}\sum_{i=1}^{N}\left(y_{pred_i} - y_{expec_i}\right)^2$$

y_{pred}	Выходное значение
y_{expec}	Фактическое значение

Начальная инициализация

$$x = random(0 \dots 1)(max - min) + max$$

x	Параметр трещины (случайное число из заданного диапазона)

Результат решения оптимизационной задачи на примере одной скважины с тремя трещинами авто-ГРП

Трещина	Параметр	Значение
1	Ширина трещины, м	0.004
	Левая полудлина, м	255
	Правая полудлина, м	255
	Азимутальный угол	90°
2	Ширина трещины, м	0.013
	Левая полудлина, м	100
	Правая полудлина, м	100
	Азимутальный угол	30°
3	Ширина трещины, м	0.006
	Левая полудлина, м	235
	Правая полудлина, м	235
	Азимутальный угол	206°

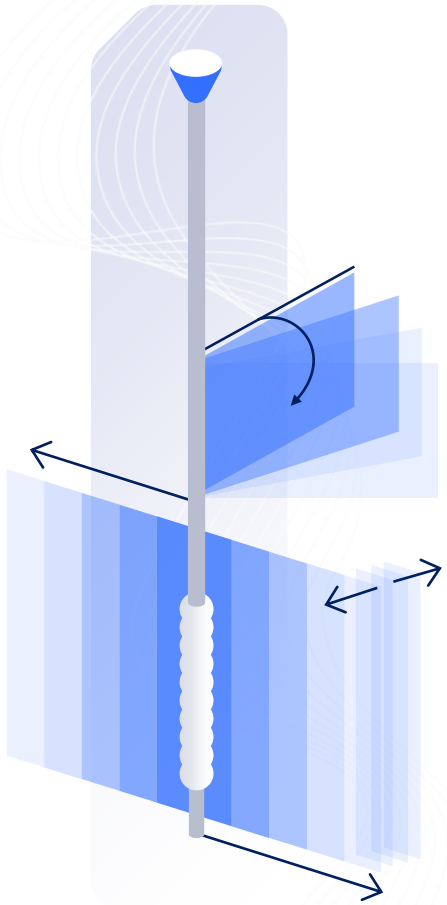

Анализ результатов решения оптимизационной задачи

Дебит нефти, м³/сут

Время адаптации модели

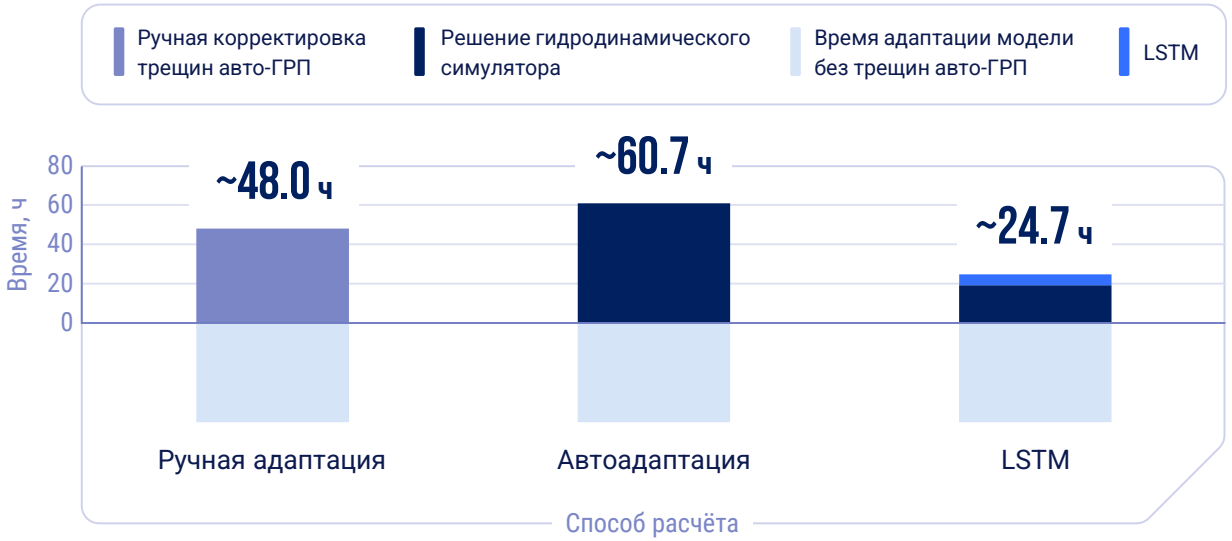

Отклонение дебита нефти в расчёте с оптимизированными параметрами трещин от ручной адаптации в **106** точках из **157** **(68%)** при среднем отклонении **8.5%** меньше отклонения между автоадаптацией и ручной адаптацией со средним отклонением **11.4%**

Таким образом, при помощи данной методики можно воспроизвести ручную адаптацию, **но потратив на это меньше времени**

Заключение

Было **проведено исследование** по оценке возможностей применения нейронной сети для подбора параметров трещин авто-ГРП с целью воспроизведения добычи нефти

С применением **комбинации машинного обучения и ГДМ** получена динамика добычи нефти, приближённая к ручному расчёту, не уступающая встроенному решению симулятора, но **с меньшими временными затратами**

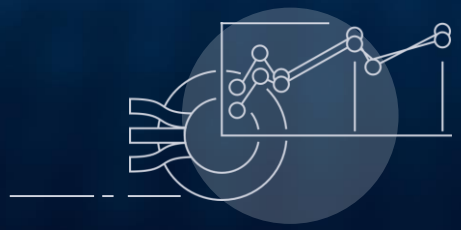

Машинное обучение в задачах автоадаптации ГДМ путем подбора трещин авто-ГРП на нагнетательных скважинах имеет **потенциал для дальнейшего развития**:

- Увеличение количества варьируемых параметров
- Задание в качестве выходных показателей ИНС добычи жидкости
- Применение алгоритма к полномасштабной ГДМ

Развитие темы

Данная работа нашла своё отражение в рамках следующего доклада, в проекте **«ЛОЗА»** (Локализация остаточных запасов), в котором в том числе решается задача автоматизации адаптации ГДМ с применением нейронных сетей с подкреплением

В ЛОЗе рассмотрен более общий подход к решению задачи, учитывающий **вариации различных параметров**, таких как: ОФП, распределения kпр по латерали и разрезу, активность аквифера, и др.

Спасибо за внимание!

Арман Казарян

Применение машинного обучения для обоснования параметров трещин авто-ГРП в задачах адаптации ГДМ

Искусственный интеллект в нефтегазовой отрасли

ТИНГ Тюменский институт нефти и газа

Машинное обучение | LSTM-прогноз | Градиентный спуск | Автоадаптация ГДМ | Прокси-модель | Авто-ГРП

Резерв

Z-нормализация

$$Z = \frac{x - \overline{X}}{S_x}$$

Где Z – нормализованная величина,

$\overline{X}$ – среднее арифметическое значение множества x,

$S_x = \sqrt{\frac{\sum(x-\overline{x})^2}{(n-1)}}$ – стандартное отклонение для множества данных x

Z–нормализация позволяет привести различные физические величины в единый цифровой диапазон и упрощает процесс обучения нейронной сети

Z–показатели могут принимать любое значение между отрицательной бесконечностью и положительной бесконечностью, но большинство z-показателей находятся в пределах 2 стандартных отклонений от среднего