


МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ  
РОССИЙСКОЙ ФЕДЕРАЦИИ  
Федеральное государственное автономное образовательное учреждение  
высшего образования  
«ТЮМЕНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»

ИНСТИТУТ МАТЕМАТИКИ И КОМПЬЮТЕРНЫХ НАУК  
Кафедра фундаментальной математики и механики

РЕКОМЕНДОВАНО К ЗАЩИТЕ В ГЭК  
Заведующий кафедрой

к. ф.-м. н.

А. П. Девятков

  
27.06 2022 г.

**ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА**  
магистерская диссертация

ОЦЕНКА ПРОГНОЗНОЙ ЭФФЕКТИВНОСТИ ПЕРЕВОДА СКВАЖИН В  
СИСТЕМУ ПОДДЕРЖАНИЯ ПЛАСТОВОГО ДАВЛЕНИЯ С  
ПРИМЕНЕНИЕМ ПРОКСИ-МОДЕЛИРОВАНИЯ

01.04.01 Математика

Магистерская программа «Вычислительная механика»

Выполнила работу  
Студентка 2 курса  
очной формы обучения



Алхименкова Анастасия  
Андреевна

Руководитель работы  
д.ф.-м.н., профессор



Родионов Сергей  
Павлович

Рецензент  
к.ф.-м.н.,  
главный инженер проекта  
ООО «ПИТЦ «Геофизика»



Марков Павел  
Владимирович

Тюмень  
2022

## ОГЛАВЛЕНИЕ

СПИСОК ТЕРМИНОВ .....	3
ВВЕДЕНИЕ.....	5
ГЛАВА 1. ТЕОРЕТИЧЕСКАЯ ЧАСТЬ.....	7
1.1. СИСТЕМА ПОДДЕРЖАНИЯ ПЛАСТОВОГО ДАВЛЕНИЯ .....	7
1.2. ПРОКСИ-МОДЕЛИРОВАНИЕ.....	11
1.3. ПРЕДСТАВЛЕНИЕ О НЕЙРОННЫХ СЕТЯХ .....	18
1.4. МЕТОДЫ НЕЙРОСЕТЕВОЙ ОПТИМИЗАЦИИ.....	22
1.4.1. МЕТОД ИМИТАЦИИ ОТЖИГА .....	24
1.4.2. МЕТОД ГРАДИЕНТНОГО СПУСКА .....	27
ГЛАВА 2. РАЗРАБОТКА АЛГОРИТМА ОЦЕНКИ ПРОГНОЗНОЙ ЭФФЕКТИВНОСТИ ПЕРЕВОДА СКВАЖИН В СИСТЕМУ ПОДДЕРЖАНИЯ ПЛАСТОВОГО ДАВЛЕНИЯ.....	29
ЗАКЛЮЧЕНИЕ .....	33
БИБЛИОГРАФИЧЕСКИЙ СПИСОК .....	35

## СПИСОК ТЕРМИНОВ

**Прокси-модель:** это математическая модель месторождения, которая позволяет регистрировать отклики показателей работы добывающих скважин на изменения в системе закачки воды и решать оптимизационные задачи разработки.

**Адаптация прокси-модели:** это процесс автоматической настройки рассчитанных в прокси-модели дебитов жидкости и доли нефти на фактические показатели.

**Нейронная сеть:** математическая модель, а также её программное или аппаратное воплощение, построенная по принципу организации и функционирования биологических нейронных сетей — сетей нервных клеток живого организма.

**Оптимизационная задача:** задача, в ходе решения которой определяются приемистости нагнетательных скважин (оптимальные режимы нагнетательных скважин), обеспечивающие достижение потенциала по добыче нефти в принятой модели ограничений.

**Обучающая выборка:** это набор исходных данных, по которым производится настройка (адаптация) модели. В нашем случае – это совокупность приемистостей нагнетательных скважин в элементе заводнения, соотнесенная по дате с дебитом жидкости и долей нефти реагирующей добывающей скважины.

**Влияющая скважина:** нагнетательная скважина, входящая в элемент заводнения добывающей скважины, которая оказывает влияние на режим работы последней.

**Реагирующая скважина:** добывающая скважина, на которой регистрируется изменение показателей эксплуатации, например увеличение обводненности или дебита жидкости, вследствие изменения режима работы нагнетательной скважины.

Пара скважин: это совокупность реагирующей добывающей и влияющей на нее нагнетательной скважины.

Оптимальный режим работы нагнетательной скважины: приемистость, полученная при решении оптимизационной задачи и обеспечивающая потенциал добычи нефти в принятой модели ограничений.

## ВВЕДЕНИЕ

Природные резервуары представляют собой сложные единые гидродинамические системы и содержат углеводороды в трещинах и порах. Чтобы повысить эффективность разработки нефтяного месторождения необходимо тщательно отслеживать динамику множества факторов, таких как пористость породы, проницаемость, нефтенасыщенность и другие. Большой интерес представляет собой пластовое давление, обуславливающее приток нефти к скважине и являющееся одним из основополагающих параметров при планировании развития месторождения. Однако в процессе эксплуатации нефтяного месторождения давление в продуктивных пластах может настолько снизиться, что результаты дальнейшей работы добывающих скважин перестанут быть удовлетворительными. В этом случае одним из вариантов решения возникшей проблемы является корректировка действующей системы поддержания пластового давления (ППД), но бурение новых нагнетательных скважин чаще всего является экономически невыгодным решением. Поэтому возникает необходимость в разработке алгоритма, позволяющего обоснованно выбирать такие скважины из добывающего фонда, что их перевод в систему ППД мог бы оказать положительное влияние на добычу нефти окружающих скважин и месторождения в целом.

На сегодняшний день работу по обоснованию перевода скважин добывающего фонда под закачку выполняют с использованием геологогидродинамического моделирования (ГГДМ), однако данный процесс является весьма дорогим относительно времени обработки, так как включает в себя большой объем входных данных и замеров. Поэтому наиболее рациональным подходом к решению вопроса оптимизации добычи в перечисленных условиях является использование упрощенных моделей пластов месторождения. Прокси-моделирование позволяет в кратчайшие сроки выполнять основные расчеты по формированию системы поддержания

пластового давления на основе минимально допустимого числа входных данных.

Целью выпускной квалификационной работы является создание экспресс-метода, позволяющего без составления сложных гидродинамических моделей проводить расчеты по формированию системы поддержания пластового давления. Для достижения поставленной цели необходимо выполнить следующие задачи:

- ознакомиться с особенностями системы поддержания пластового давления и алгоритмами нейросетевой оптимизации;
- разработать алгоритм при оценке прогнозной эффективности перевода добывающих скважин в нагнетательный фонд на основе прокси-модели;
- протестировать предлагаемый алгоритм на основе данных реального месторождения;
- сравнить полученные результаты с гидродинамической моделью.

## ГЛАВА 1. ТЕОРЕТИЧЕСКАЯ ЧАСТЬ

### 1.1. СИСТЕМА ПОДДЕРЖАНИЯ ПЛАСТОВОГО ДАВЛЕНИЯ

Разработка и эксплуатация месторождений подразумевает под собой применение методов по эффективной добыче нефти и газа из природных резервуаров. Когда заканчивается период первичной добычи, начинающийся с первоначального открытия месторождения и продолжающийся до тех пор, пока первоначальные источники энергии для вытеснения нефти не перестанут в одиночку поддерживать рентабельные темпы добычи, возникает необходимость в применении дополнительных источников воздействия на продуктивный пласт. Следствием окончания периода первичной добычи является падение пластового давления, и поэтому вторичная добыча требует увеличения пластового давления.

Одним из наиболее популярных методов поддержания пластового давления является заводнение. Поддержание пластового давления означает закачку газа или жидкости в резервуар, основным эффектом чего является смягчение последствий падения давления в резервуаре и сохранение его энергии. В конечном счете, целью поддержания давления является повышение нефтеотдачи.

С начала ведения промышленности вода добывается из скважин вместе с нефтью, и по мере снижения дебита нефти дебит воды часто увеличивался. Эту воду обычно сливали в близлежащие ручьи или реки. В 1920-х годах началась практика обратной закачки пластовой воды в пористые и проницаемые подземные пласты, в том числе в интервал пласта, из которого первоначально поступали нефть и вода. К 1930-м годам обратная закачка попутной воды стала обычной практикой на нефтяных месторождениях.

Обратная закачка воды была впервые систематически осуществлена на нефтяном месторождении Брэдфорт в Пенсильвании, США. Здесь первоначальный подход кругового заводнения был заменен линейным заводнением, при котором два ряда добывающих скважин располагались в

шахматном порядке по обеим сторонам равномерно расположенного ряда водонагнетательных скважин. Вслед за линейным заводнением начали применять и другие варианты расположения сетки скважин при внутриконтурном заводнении (рис. 1.1):

- точечные сетки скважин (четырёх-, пяти-, семи-, девяти-, одиннадцати-, двенадцатиточечные);
- линейные сетки (рядная, шахматная);
- круговые (блочные) сетки;
- избирательные.




Рисунок 1.1 – Основные системы разработки

Большая часть технологий и общепринятой практики заводнения была разработана в США между 1940 и 1970 гг. Кроме того, в США были пробурены тысячи близко расположенных скважин, так что последствия закачки воды были более очевидными и, следовательно, более понятными.

В дополнение к необходимости утилизировать попутную воду, которая добывалась вместе с нефтью, несколько других факторов сделали заводнение логичным и экономичным методом увеличения добычи на нефтяных



месторождениях. Очень рано было признано, что в большинстве коллекторов только небольшой процент первоначальной нефти в пласте извлекался в течение периода добычи из-за истощения природной энергии коллекторов. Для добычи большого количества оставшейся нефти потребовались дополнительные методы извлечения. Ранний успех закачки воды в увеличении периода добычи нефти на долгие годы сделал заводнение естественным шагом после первичной добычи для извлечения дополнительной нефти из пластов, дебит нефти которых снизился до очень низкого уровня.

Другими ключевыми факторами, которые способствовали развитию и расширению использования заводнения, были:

- дешевизна воды;
- ее доступность (из близлежащих ручьев, рек или океанов, или из скважин, пробуренных в более мелкие или более глубокие подземные водоносные горизонты);
- эффективное приведение нагнетания к тому, что добывающие скважины, находясь вблизи водонагнетательных скважин, изнашивались с большей скоростью из-за повышенного пластового давления.

Одновременно была выявлена и другая причина успеха заводнения — вода имеет такие вязкость, плотность и смачивающие свойства, что их влияние показывает, насколько эффективно она будет вытеснять нефть.

К 1970-м годам большинство наземных месторождений в СССР, США и Китае, для которых заводнение было логичным процессом добычи, разрабатывались с использованием этой технологии в различных конфигурациях скважин. С тех пор многие крупномасштабные проекты по закачке воды были применены к нефтяным пластам в различных местах.

Помимо прочего, развитие разработки месторождений сопровождалось моделированием различных процессов, возникающих при эксплуатации: возможность описания течений жидкостей, газов и их смесей в трещиноватых и пористых средах обеспечивает решение широкого круга прикладных задач. На базе новых методов и приложений, таких как STORM, SCRF, IRAP и пр.,

начали создаваться первые полноценные геологические модели. Позже появились и гидродинамические симуляторы ROXAR, ECLIPSE, PETREL и другие, дающие возможность интегрировать различные методы и источники данных в одну модель.

Моделирование месторождений – трудоемкий процесс, требующий тщательного контроля и качественной обработки информационных данных, и достижение наиболее эффективного режима разработки сейчас невозможно без применения современных методов математического моделирования и оптимального управления процессами нефтедобычи. Использование нейронных сетей при формировании моделей месторождений помогает учитывать многие факторы и закономерности, которые не всегда замечает человек или симулятор.

## 1.2. ПРОКСИ-МОДЕЛИРОВАНИЕ

Заводнение – способ воздействия на пласт при разработке нефтяных месторождений, при котором поддержание и восстановление пластового давления и баланса энергии осуществляются закачкой воды. Заводнение позволяет значительно уменьшить число нефтяных скважин и резко повысить их дебиты, снизить затраты добываемой нефти.

Чтобы повысить дебиты нефти добывающих скважин, необходимо правильно организовать режимы работы нагнетательных скважин, а именно оптимизировать этот процесс.

Для оптимизации системы заводнения необходимо получить зависимость, описывающую поведение добычи жидкости и нефти добывающих скважин от закачки воды в пласт окружающих их влияющих нагнетательных скважин. Математическим аппаратом для получения данной зависимости являются искусственные нейронные сети.

Прокси–моделирование является альтернативной 3D моделям в решении задач оптимизации технологического процесса извлечения нефти. Принцип функционирования нейронной сети в задачах управления заводнением заключается в установлении законов взаимодействия скважин на основе исторических показателей разработки. В частности, для решения оптимизационных задач в нефтедобыче таковым является взаимосвязь дебита нефти добывающей и приемистостей окружающих нагнетательных скважин.

Процесс управления режимами работы нагнетательных скважин с использованием нейронных сетей можно разделить на два основных этапа:

- Построение нейронной сети и ее обучение (адаптация) к условиям и фактическим показателям эксплуатации фонда скважин.
- Решение оптимизационной задачи распределения необходимого объема закачки.

Зависимость, описывающая поведение дебита жидкости добывающей скважины в зависимости от приемистости влияющей нагнетательной

скважины, это логистическая монотонно возрастающая дифференцируемая в любой точке функция, не выходящая за предел максимального исторического значения дебита жидкости:

$$g_j(q_{i,t}^{inj}) = \frac{g_j^{max}}{1 + e^{-s_{i,j}(q_{i,t}^{inj} - q_{0,i,j})}},$$

где  $g_j(q_{i,t}^{inj})$  – зависимость дебита жидкости добывающей скважины  $j$  от приемистости нагнетательной скважины  $i$  на дату обучения  $t$ ;  $q_{i,t}^{inj}$  – приемистость нагнетательной скважины  $i$  на дату обучения  $t$ , м<sup>3</sup>/сут;  $g_j^{max}$  – настроечный параметр, определяющий максимальное значение дебита жидкости добывающей скважины  $j$ , т/сут;  $s_{i,j}$  – настроечный параметр, определяющий изменение дебита жидкости добывающей скважины  $j$  при изменении приемистости нагнетательной скважины  $i$  на 1 м<sup>3</sup>, т/м<sup>3</sup>;  $q_{0,i,j}$  – настроечный параметр, определяющий минимальную приемистость нагнетательной скважины  $i$ , которая необходима для получения существенного значения дебита жидкости добывающей скважины  $j$ , м<sup>3</sup>/сут.

Как правило, на одну добывающую скважину влияет несколько нагнетательных скважин, поэтому функция зависимости примет модифицированный вид:

$$G_j(q_{i,t}^{inj}) = \frac{\sum_{i=1}^{M_j^{react}} (g_j(q_{i,t}^{inj}) \times react_{i,j}^{liq})}{\sum_{i=1}^{M_j^{react}} react_{i,j}^{liq}},$$

где  $G_j(q_{i,t}^{inj})$  – зависимость дебита жидкости добывающей скважины  $j$  от приемистостей нагнетательных скважин  $i$  на дату обучения  $t$ ;  $M_j^{react}$  – количество нагнетательных скважин, влияющих на одну добывающую скважину  $j$ ;  $react_{i,j}^{liq}$  – настроечный параметр, определяющий долю в суммарном дебите жидкости добывающей скважины  $j$ , приходящейся от нагнетательной скважины  $i$ , д. ед.

Обучение прокси-модели на дебит жидкости сводится к минимизации целевой функции среднеквадратической ошибки:

$$h = \sqrt{\frac{1}{N} \cdot \sum_{t=date^{train\_begin}}^{date^{train\_end}} (G_j(q_{i,t}^{inj}) - q_{j,t}^{liq})^2} \rightarrow \min,$$

где  $date^{train\_begin}$  – дата начала обучающей выборки, сут;  $date^{train\_end}$  – дата окончания обучающей выборки, сут;  $N$  – количество элементов обучающей выборки;  $q_{j,t}^{liq}$  – фактический дебит жидкости добывающей скважины  $j$  на дату обучения  $t$ , т/сут. В ходе решения задачи минимизации получают оптимальные значения параметров  $s_{i,j}, q_{0i,j}, react_{i,j}^{liq}$  таким образом, чтобы значение среднеквадратического отклонения между фактическими и рассчитанными значениями дебитов жидкости стремилось к минимуму. В результате прокси-модель адаптируется на исторические показатели работы каждой добывающей скважины, с помощью чего возможен прогноз дебита жидкости добывающих скважин в зависимости от режима работы окружающих их нагнетательных скважин.

Существует два случая изменения доли нефти при изменении закачки нагнетательных скважин. Для каждого из этих случаев будет своя зависимость изменения доли нефти добывающей скважины, при изменении закачки нагнетательной скважины:

- 1) При увеличении закачки ( $(q_{i,t}^{inj} - q_{i,t-1}^{inj}) > 0$ ) происходит снижение доли нефти ( $\Delta f_{j,t}^n < 0$ ). Функция уменьшения доли нефти имеет вид:

$$f_j^{dec}(q_{i,t}^{inj}) = c_{i,j}^{dec} \cdot \left( \exp^{d_{i,j}^{dec} \cdot f_{j,t-1}^n} - 1 \right) \cdot \ln \left( \frac{q_{i,t}^{inj}}{q_{i,t-1}^{inj}} \right);$$

- 2) При уменьшении закачки ( $(q_{i,t}^{inj} - q_{i,t-1}^{inj}) < 0$ ) происходит увеличение доли нефти ( $\Delta f_{j,t}^n > 0$ ). Функция роста доли нефти имеет вид:

$$f_j^{gr}(q_{i,t}^{inj}) = c_{i,j}^{gr} \cdot \left( \exp^{d_{i,j}^{gr} \cdot f_{j,t-1}^n} - \exp^{d_{i,j}^{gr}} \right) \cdot \ln \left( \frac{q_{i,t-1}^{inj}}{q_{i,t}^{inj}} \right),$$

где  $f_{j,t}^n$  – доля нефти добывающей скважины  $j$  на дату обучения  $t$ ;  
 $q_{i,t}^{inj}$  – приемистость нагнетательной скважины  $i$  на дату обучения  $t$ ;  
 $q_{i,t-1}^{inj}$  – приемистость нагнетательной скважины  $i$  на дату обучения  $t - 1$ ;  $c_{i,j}^{dec}$ ,  $d_{i,j}^{dec}$ ,  $c_{i,j}^{gr}$ ,  $d_{i,j}^{gr}$  – настроечные параметры.

Так как существует два случая изменения доли нефти добывающей скважины  $j$  в зависимости от изменения приемистости влияющих на нее нагнетательных скважин  $i$ , то в общую функцию изменения доли нефти добавляется логистическая функция, которая будет определять силу действия каждой функциональной зависимости (увеличения или снижения доли нефти).

Если происходит увеличение приемистости (что повлечет снижение доли нефти), то функция переключателя принимает вид:

$$p^{dec} = \frac{1}{1 + e^{-a \cdot (q_{i,t}^{inj} - q_{i,t-1}^{inj})}}$$

где  $a$  - настроечный параметр кривизны функции.

Если происходит снижение приемистости (что повлечет увеличение доли нефти), то функция переключателя принимает вид:

$$p^{gr} = \frac{1}{1 + e^{a \cdot (q_{i,t}^{inj} - q_{i,t-1}^{inj})}}$$

В общем виде, целевая функция, которую необходимо оптимизировать для минимизации расхождения фактической и расчетной доли нефти имеет вид среднеквадратической ошибки:

$$H = \sqrt{\frac{1}{N} \cdot \sum_{t=date^{test\_begin}}^{date^{test\_end}} (f_{j,t}^n -$$

$$\frac{- \left( f_{j,t-1}^n + \sum_{i=1}^{M^{react}_j} \left( p^{dec} \cdot \frac{f_j^{dec}(q_{i,t}^{inj})}{M^{react}_j} \right) + \sum_{i=1}^{M^{react}_j} \left( p^{gr} \cdot \frac{f_j^{gr}(q_{i,t}^{inj})}{M^{react}_j} \right) \right)^2}{}} \rightarrow min$$

где  $date^{train\_begin}$  – дата начала обучающей выборки;  $date^{train\_end}$  – дата окончания обучающей выборки;  $N$  – количество элементов обучающей выборки;  $M^{react}_j$  – количество нагнетательных скважин действующих на одну добывающую скважину  $j$ ;  $f^n_{j,t-1}$  – доля нефти добывающей скважины  $j$  на дату  $t - 1$ , д.ед.

Адаптация прокси-модели на дебит жидкости и долю нефти в зависимости от приемистостей нагнетательных скважин необходима для получения функции суточной добычи нефти.

Известна формула получения суточной добычи нефти через дебит жидкости  $q_j^{liq}$  и долю нефти  $f_j^n$  добывающей скважины  $j$ :

$$q_j^{oil} = q_j^{liq} \cdot f_j^n.$$

При адаптации прокси-модели для каждой добывающей скважины определяются значения настроечных параметров функции дебита жидкости и изменения доли нефти, поэтому функцию суточной добычи нефти можно записать как:

$$\begin{aligned} q_j^{oil}(x_i) = & \\ = q_j^{liq}(x_i) \cdot (f_j^n + & \sum_{i=1}^{M_j^{react}} \left( \frac{1}{1 + e^{-a(x_i - x_i^0)}} \cdot \frac{c_{i,j}^{dec} \cdot (exp^{d_{i,j}^{dec} \cdot f_j^n} - 1) \cdot \ln \frac{x_i}{x_i^0}}{M_j^{react}} \right) + \\ & + \sum_{i=1}^{M_j^{react}} \left( \frac{1}{1 + e^{a(x_i - x_i^0)}} \cdot \frac{c_{i,j}^{gr} \cdot (exp^{d_{i,j}^{gr} \cdot f_j^n} - exp^{d_{i,j}^{gr}}) \cdot \ln \frac{x_i^0}{x_i}}{M_j^{react}} \right), \end{aligned}$$

где  $x_i$  – оптимальное значение приемистости нагнетательной скважины  $i$ , м<sup>3</sup>/сут;  $x_i^0$  – текущая приемистость нагнетательной скважины  $i$ , м<sup>3</sup>/сут;  $f_j^n$  – текущая доля нефти добывающей скважины  $j$ , д. ед.;  $q_j^{liq}(x_i)$  – зависимость дебита жидкости добывающей скважины  $j$  от приемистости влияющих на нее нагнетательных скважин  $i$ .

Итак, нейронная сеть, или прокси-модель, представляет собой математическую модель взаимовлияния нагнетательных и добывающих скважин в рамках единого объекта разработки. Для построения прокси-модели используются первичные данные суточных замеров дебита жидкости и обводненности добывающих, а также приемистость нагнетательных скважин. Процессом обучения нейронной сети следует называть процедуру поиска зависимости между показателями приемистости влияющих нагнетательных скважин и показателями работы (дебит жидкости, обводненность) зависимой добывающей скважины. Результатом настройки нейронной сети является функциональное описание связи показателей работы (дебит жидкости, обводненность) каждой добывающей скважины и показателей работы (приемистость) соседних влияющих нагнетательных скважин.

На основе уже обученной нейронной сети решается оптимизационная задача в следующей постановке: «Как распределить доступные ресурсы таким образом, чтобы обеспечить максимум целевого показателя разработки – суточной добычи нефти». Оптимизационная задача решается в условиях ограничений, накладываемых как на приемистость нагнетательных скважин, так и на дебит жидкости добывающих скважин. Эти ограничения обусловлены геологическим строением залежей, параметрами и состоянием объектов обустройства, экономическими условиями, логистикой, организацией материально-технического снабжения. Среди них:

- 1) Сумма приемистостей всех нагнетательных скважин после оптимизации должна равняться сумме приемистостей на текущую дату:

$$x_1 + x_2 + \dots + x_{N^{inj}} - \sum_{i=1}^{N^{inj}} x_i^0 = 0,$$

где  $N^{inj}$  – общее количество нагнетательных скважин

- 2) Приемистости нагнетательных скважин не должны превышать максимальную приемистость:

$$g_p(x_i) = x_i - x_i^{max} \leq 0$$



3) Приемистости нагнетательных скважин должны быть положительными:

$$g_q(x_i) = -x_i + x_i^{min} \leq 0$$

Для определения оптимальных режимов вводится целевая функция, являющаяся суммарной функцией суточной добычи нефти всех добывающих скважин объекта разработки:

$$f(x_i) = \sum_{j=1}^{N^{prod}} (q_j^{liq}(x_i) \cdot (f_j^n + \sum_{i=1}^{M_j^{react}} \left( \frac{1}{1 + e^{-a(x_i - x_i^0)}} \cdot \frac{c_{i,j}^{dec} \cdot (exp^{d_{i,j}^{dec} \cdot f_j^n} - 1) \cdot \ln \frac{x_i}{x_i^0}}{M_j^{react}} \right) + \sum_{i=1}^{M_j^{react}} \left( \frac{1}{1 + e^{a(x_i - x_i^0)}} \cdot \frac{c_{i,j}^{gr} \cdot (exp^{d_{i,j}^{gr} \cdot f_j^n} - exp^{d_{i,j}^{gr}}) \cdot \ln \frac{x_i}{x_i^0}}{M_j^{react}} \right) \right) \rightarrow \max,$$

где  $N^{prod}$  – количество добывающих скважин на объекте разработки.

В совокупности с ограничениями, накладываемыми на приемистости нагнетательных скважин, целевая функция суммарной суточной добычи нефти примет вид:

$$F(x_i, r) = -f(x_i) - \frac{1}{2r^k} \left( \sum_{i=1}^{N^{inj}} x_i \right)^2 + r^k \cdot \left( \sum_{p=2}^{N^{inj}+1} (e^{a \cdot g_p(x_i)}) + \sum_{q=N^{ing}+2}^{2N^{inj}+1} (e^{a \cdot g_p(x_i)}) \right),$$

где  $r^k, a$  – параметры штрафа.

Результатом решения оптимизационной задачи является комбинация режимов работы всех нагнетательных скважин (оптимальные режимы), отвечающая заданным ограничениям и обеспечивающая максимизацию целевого показателя суточной добычи нефти.

### 1.3. ПРЕДСТАВЛЕНИЕ О НЕЙРОННЫХ СЕТЯХ

Нейронные сети и глубокое обучение (deep learning) являются важными темами в современной технологической отрасли. Они находят большое применение в интеллектуальном анализе данных — прогнозировании, принятии решений, распознавании образов, оптимизации.

В машинном обучении искусственные нейронные сети представляют собой семейство моделей, вдохновленных биологическими нейронными сетями, посылающими и обрабатывающими химические и электрические сигналы, и используются для аппроксимации функций, которые могут зависеть от большого количества входных данных. Искусственные нейронные сети представлены как системы взаимосвязанных «нейронов», которые обмениваются сообщениями друг с другом. Соединения имеют веса, которые можно настраивать, что делает нейронные сети адаптивными к входным данным и способными к обучению. Способность искусственных нейронных сетей аппроксимировать неизвестные функции с высокой точностью лежит в основе их популярности.

#### СТРУКТУРА НЕЙРОННОЙ СЕТИ

Искусственные нейронные сети обрабатывают информацию аналогично тому, как это делает человеческий мозг. Сеть состоит из большого количества сильно взаимосвязанных обрабатывающих элементов (нейронов), работающих параллельно для решения конкретной задачи. Обучение нейронных сетей основывается на примерах, называемых тестовой и обучающей выборками. За последние несколько лет ИНС дали возможность для исследований, разработок и применения к множеству реальных проблем.

Нейронная сеть состоит из элементов обработки, которые формируют сети со взвешенными функциями для каждого входного сигнала. Эти элементы обычно расположены в виде последовательности слоев с несколькими соединениями между ними. Структура нейронных сетей имеет три типа

уровней: входной уровень, который получает данные из внешних источников, скрытый уровень, который выполняет вычисления на основе предоставленной функции, и выходной уровень, который генерирует выходные данные на основе предоставленных входных данных (рис. 1.2).

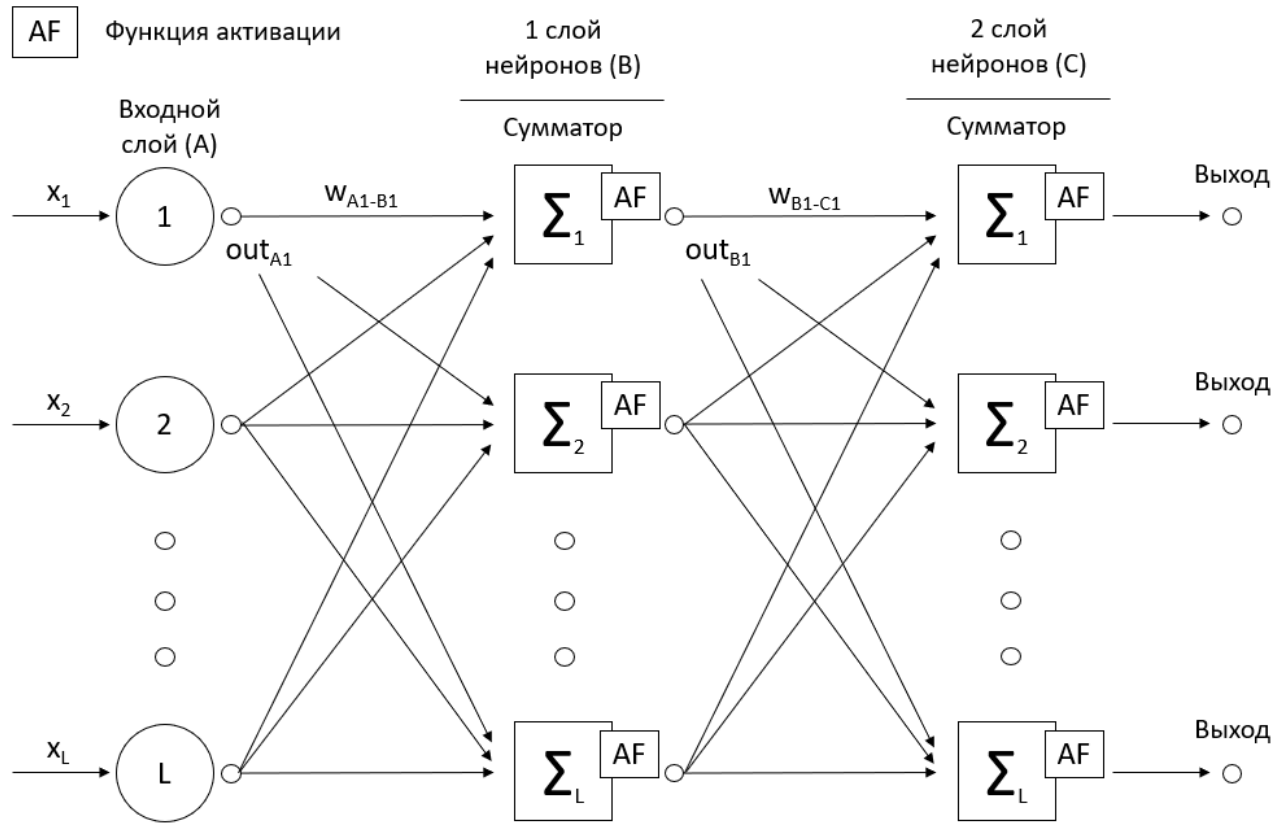


Рисунок 1.2 – Пример структуры нейронной сети с прямой связью

Таким образом, искусственная нейронная сеть — это хорошо организованная система обработки информации, которая имеет характеристики, аналогичные характеристикам биологической нейронной сети, состоящая из в значительной степени взаимосвязанных элементов обработки, известных как блоки, узлы или нейроны. Эти элементы обычно работают параллельно и соединены друг с другом с помощью соединительных звеньев. Соединительные линии имеют веса, которые содержат данные, относящиеся к входному сигналу. Нейроны используют эти данные для решения конкретной задачи. Поведение нейронной сети описывается ее способностью к обучению, анализу и обобщению обучающих данных, имеющих сходство с поведением человеческого мозга. Эти сети состоят из в значительной степени

взаимосвязанных обрабатывающих нейронов, которые по своей природе параллельны.

Математически сетевая функция нейрона  $g(x)$  определяется как совокупность других функций  $h_i(x)$ , которые в дальнейшем могут быть определены как совокупность еще некоторых функций. Это можно удобно представить в виде сетевой структуры со стрелками, изображающими зависимости между переменными (рис. 1.2). Широко используемым типом композиции является нелинейная взвешенная сумма, где  $g(x) = K(\sum_i w_i h_i(x))$ , где  $K$  представляет собой некоторую предопределенную функцию активации, например, гиперболический тангенс. Обычно набор функций  $g_i$  представляется как вектор  $h = (h_1, h_2, \dots, h_n)$ .

Учитывая конкретную задачу для решения и класс функций  $G$ , обучение означает использование набора наблюдений для поиска  $g^* \in G$ , что позволяет найти наиболее оптимальное решение. Это влечет за собой определение функции затрат (целевой функции)  $F(\bar{x}): X \rightarrow \mathbb{R}$  таким образом, чтобы для оптимального решения выполнялось  $g^*, F(\bar{x}) \leq F(x) \forall x \in X$ , то есть ни одно решение не было более оптимальным, чем  $\bar{x}$ .

Большинство искусственных нейронных сетей содержат некоторую форму "правила обучения", которое изменяет веса соединений в соответствии с входными шаблонами, с которыми они представлены изначально. Целевая функция  $C$  является важной концепцией в обучении, поскольку она является мерой того, насколько далеко конкретное решение находится от оптимального в контексте решаемой проблемы. Алгоритмы обучения выполняют поиск в пространстве решений, чтобы среди них найти наиболее оптимальное.

Сетевая структура искусственной нейронной сети должна быть простой и понятной. В основном существует два типа механизмов: повторяющаяся и неперiodическая структура. Повторяющаяся структура также известна как автоассоциативная сеть, или сеть обратной связи, а неповторяющаяся структура также известна как ассоциативная сеть, или сеть прямой связи. В сети прямой связи сигнал распространяется только в одном направлении, а в сети обратной

— в обоих направлениях за счет введения петель в сети. На текущий момент существует множество типов нейронных сетей, которые можно классифицировать в зависимости от их структуры, потока данных, используемых нейронов и их плотности, слоев и их глубинных фильтров активации и так далее.

Таким образом, искусственные нейронные сети рассматриваются как простые математические модели для улучшения существующих технологий анализа данных. Хотя они не и сравнимы с мощностью человеческого мозга, нейросети являются основным материалом для создания искусственного интеллекта.

## 1.4. МЕТОДЫ НЕЙРОСЕТЕВОЙ ОПТИМИЗАЦИИ

Обычно, когда речь идет об оптимизации процессов с использованием искусственных нейронных сетей, целевой функцией является функция среднеквадратичной ошибки (функция потерь). Необходимо отыскать оптимальные значения весов нейронной сети, чтобы минимизировать целевую функцию. Хотя методы поиска на основе градиентного спуска, такие как метод обратного распространения ошибки, в настоящее время являются наиболее широко используемыми методами оптимизации для обучения нейронных сетей, было показано, что эти градиентные методы сильно ограничены в их способности находить глобальные экстремумы. Методы поиска глобальных экстремумов были определены в качестве потенциального решения этой проблемы.

Вопрос о решении ряда задач с использованием нейронных сетей поднимается и в нефтегазовой отрасли. Значение задач проектирования и разработки месторождений состоит в обобщении и анализе информации о залежах с целью обоснования наиболее эффективных способов организации эксплуатационной деятельности. Одной из таких задач является распределение объемов закачки в нагнетательные скважины с целью получить максимальную добычу нефти по месторождению. Однако в ходе исследования можно столкнуться с проблемой подбора входных данных, участвующих в поставленной задаче оптимизации управления заводнением. Эту проблему можно исключить на этапе составления нейронной сети, используя методы нейросетевой оптимизации.

В общем виде математическую задачу оптимизации можно сформулировать следующим образом: минимизировать целевую функцию  $F(\bar{x}): X \rightarrow \mathbb{R}$  с учетом ограничений, накладываемых на управляемые переменные:  $F(\bar{x}) \rightarrow \min_{x \in X} f(x)$ .

Под минимизацией функции  $n$  переменных  $f(x) = (x_1, \dots, x_N)$  на заданном множестве  $D$   $n$ -мерного арифметического пространства  $R^{|X|}$

понимается определение хотя бы одной из точек минимума этой функции на множестве  $D$ , а также, если это необходимо, и минимального на множестве  $D$  значения  $f(x)$ .

В условиях данной работы рассматривается задача оптимизации работы нагнетательных скважин с целью максимизировать суммарный дебит нефти. Общая математическая постановка задачи запишется следующим образом:

$$\max_{X \in D \subset R^{|X|}} f(X) = f(X^*)$$

где  $X$  – вектор значений приемистостей всех нагнетательных скважин,  $X = (x_1, x_2, \dots, x_N)^T$ ;  $f(X)$  – функция суммарного дебита нефти при заданных приемистостях на нагнетательных скважинах  $X$ ,  $X^*$  – искомое распределение закачки по скважинам, которое обеспечивает максимальный суммарный дебит нефти.

Множество допустимых значений  $D$  вектора  $X$  можно записать следующим образом:

$$D = \{X | x_i^{min} \leq x_i \leq x_i^{max}, \sum_i x_i \leq Q_{inj}^{sum}\},$$

где  $Q_{inj}^{sum}$  – максимальная суммарная закачка нагнетательных скважин.

Одним из хорошо известных методов глобального поиска является метод имитации отжига.

### 1.4.1. МЕТОД ИМИТАЦИИ ОТЖИГА

Для решения задач оптимизации существует множество методов, нацеленных на получение качественного решения в зависимости от входных параметров. Метод имитации отжига позволяет находить решение, достаточно близкое к оптимальному, за приемлемое время. Метод имитации отжига носит название, аналогичное процессу, который происходит, когда физические вещества, такие как металлы, нагреваются до высокого энергетического уровня, то есть расплавляются, а затем постепенно охлаждаются до достижения некоторого твердого состояния. Цель этого процесса — достичь самого низкого энергетического состояния. В этом процессе физические вещества обычно переходят из более высоких энергетических состояний в более низкие, если процесс охлаждения достаточно медленный, поэтому естественным образом происходит минимизация. Однако из-за естественной изменчивости на каждой стадии процесса охлаждения существует некоторая вероятность того, что произойдет переход в состояние с более высокой энергией. Поскольку энергетическое состояние естественным образом снижается, вероятность перехода в более высокое энергетическое состояние уменьшается. По сути, имитируемый отжиг рисует начальную случайную точку, чтобы начать ее поиск. С этого момента алгоритм делает шаг в пределах диапазона, заданного пользователем.

Значение целевой функции этой новой точки затем сравнивается со значением начальной точки, чтобы определить, является ли новое значение меньшим. В случае минимизации, если значение целевой функции уменьшается, оно автоматически принимается и становится точкой, с которой будет продолжен поиск. Затем алгоритм перейдет к следующему шагу. Принимая точки с более высокими значениями целевой функции, алгоритм имитации отжига способен избежать локальных оптимумов. По мере движения в соответствии с алгоритмом длина шагов уменьшается, приближаясь к окончательному решению. Критерии Метрополиса используют исходные



пользовательские параметры  $T$ , вводимымся в данном случае как температура, и  $RT$ , вводимымся как коэффициент снижения температуры, для определения вероятности принятия более высокого значения целевой функции. Параллельно реальному процессу отжига, по мере уменьшения  $T$  вероятность принятия более высоких значений уменьшается.  $T$  уменьшается на функцию  $T_{i+1} = RT * T_i$ , где  $i$  — номер итерации вычисления функции после каждых  $NT$  итераций, где  $NT$  — это предустановленный параметр, который устанавливает количество итераций между понижениями температуры. Производительность алгоритма имитации отжига зависит от заданных пользователем параметров.

Также широко используется метод имитации отжига, использующий для получения результата распределение Гиббса. Математически такое решение ищется последовательным вычислением точек  $\bar{x}_0, \bar{x}_1, \dots$  из пространства  $X$  [ $\bar{x} = (x_1, \dots, x_n) \in X$ ]. Каждая точка, начиная с  $\bar{x}_1$ , «претендует» на то, чтобы лучше предыдущих приближать решение. Алгоритм принимает точку  $\bar{x}_0$  как исходные данные. На каждом шаге вычисляется новая точка и понижается значение величины, понимаемой как «температура». Алгоритм останавливается по достижении точки, которая оказывается при температуре 0. Точка  $\bar{x}_{i+1}$  по алгоритму получается на основе текущей точки  $\bar{x}_i$  следующим образом: к точке  $\bar{x}_i$  применяется оператор  $A$ , который случайным образом модифицирует соответствующую точку, в результате чего получается новая точка  $\bar{x}^*$ . Точка  $\bar{x}^*$  становится точкой  $\bar{x}_{i+1}$  с вероятностью  $P(\bar{x}^*, \bar{x}_{i+1})$ , которая вычисляется в соответствии с распределением Гиббса:

$$P(\bar{x}^* \rightarrow \bar{x}_{i+1} | \bar{x}_i) = \begin{cases} 1, & F(\bar{x}^*) - F(\bar{x}_i) < 0 \\ \exp\left(-\frac{F(\bar{x}^*) - F(\bar{x}_i)}{Q_i}\right), & F(\bar{x}^*) - F(\bar{x}_i) \geq 0 \end{cases}$$

Здесь  $Q_i > 0$  — элементы произвольной убывающей, сходящейся к нулю положительной последовательности, которая задает аналог падающей температуры в кристалле.

Алгоритм имитации отжига не гарантирует нахождения минимума функции, однако при правильной постановке условий генерации случайной

точки в пространстве  $X$ , как правило, происходит улучшение начального приближения.

### 1.4.2. МЕТОД ГРАДИЕНТНОГО СПУСКА

Градиент функции в любой точке  $x$  показывает направление наибольшего локального увеличения  $f(x)$ . Поэтому при поиске минимума можно попробовать двигаться в направлении, противоположном градиенту в данной точке, то есть в направлении наискорейшего спуска. Метод градиентного спуска является одним из классических алгоритмов оптимизации и имеет большое количество модификаций.

Идея метода состоит в том, чтобы двигаться к минимуму в направлении наиболее быстрого убывания функции, определяющегося антиградиентом. Реализация происходит следующим образом.

На первом этапе выбирается начальная точка каким-либо способом. В ней вычисляется градиент рассматриваемой функции и происходит движение в направлении, обратном градиенту. В результате происходит попадание в точку, значение функции в которой меньше первоначального. В новой точке процедура повторяется: вычисляется градиент функции, делается шаг в обратном градиенту направлении. Таким образом, продолжая данные действия, происходит движение в сторону убывания функции.

Математически алгоритм запишется так:

1. Инициализируется  $x_1$  случайным значением из  $\mathbb{R}$  ;
2. Присваивается шаг  $i = 1$ ;
3. Определяется следующая точка  $x_{i+1} = x_i - \varepsilon f'(x_i)$ , где  $\varepsilon$  – коэффициент сокращения шага;
4.  $i + +$ ;
5. Проверяется условие выхода  $f(x_i) - f(x_{i+1}) > c$ , где  $c$  – некоторое заданное значение точности;
6. Если условие выполняется, то расчет возвращается на третий шаг.

Аналогичный алгоритм действий предлагается и для поиска максимума, но за исключением того, что движение происходит в сторону градиента. То есть формула поиска точек запишется как  $x_{i+1} = x_i + \varepsilon f'(x_i)$ .

В качестве минуса метода градиентного спуска можно выделить тот факт, что процесс поиска минимума целевой функции может закончиться в стационарной точке. Для выхода из нее необходимо предпринять дополнительные меры – определить тип точки и в случае положительного ответа применить любой не градиентный метод для выхода из стационарной точки, и далее продолжить поиск методом градиентного спуска.

## ГЛАВА 2. РАЗРАБОТКА АЛГОРИТМА ОЦЕНКИ ПРОГНОЗНОЙ ЭФФЕКТИВНОСТИ ПЕРЕВОДА СКВАЖИН В СИСТЕМУ ПОДДЕРЖАНИЯ ПЛАСТОВОГО ДАВЛЕНИЯ

Применение математической прокси-модели на основе нейронных сетей позволяет адаптировать фактические и рассчитанные дебиты нефти и жидкости добывающих скважин в зависимости от приемистостей влияющих на нее нагнетательных скважин таким образом, чтобы расхождение между этими данными было минимальным. При этом составляется функциональная зависимость дебита жидкости и доли нефти от приемистости влияющих нагнетательных скважин (рис. 2.1):

$$f(X) = F_{\Pi},$$

где  $X$  – вектор приемистостей (размерность равна количеству нагнетательных скважин),  $F_{\Pi}$  – функция, полученная при адаптации прокси-модели, ставящая в соответствие вектору приемистостей суммарный дебит нефти/жидкости. В качестве исходных данных используют первичную промысловую информацию такую, как ежедневные замеры дебита жидкости и обводненности добывающих скважин, приемистости нагнетательных скважин и информацию о виде и датах проведения геолого-технических мероприятий.

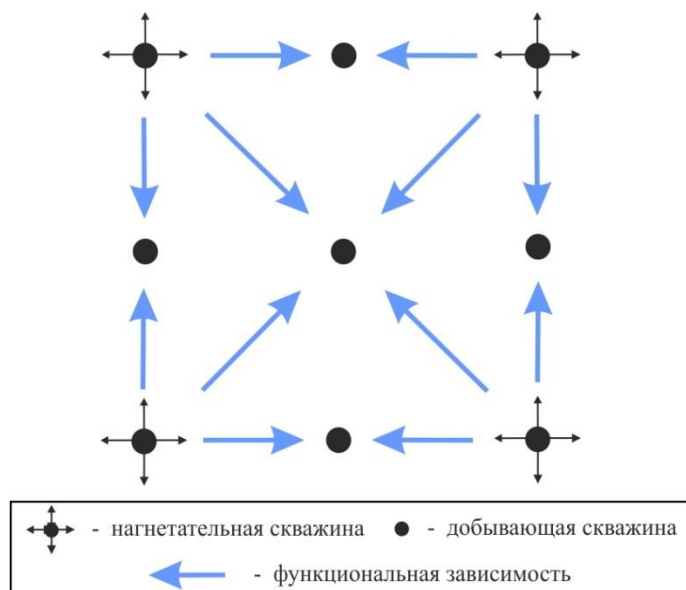


Рисунок 2.1- Схема влияния нагнетательных и добывающих скважин

На основе обученной нейронной сети производится решение оптимизационной задачи распределения необходимого объема закачки методом градиентного спуска или методом имитации отжига таким образом, чтобы суточная добыча нефти была максимальной. В качестве целевой функции выбирается сумма зависимостей дебита нефти добывающих скважин от приемистости влияющих нагнетательных скважин. Оптимизационная задача решается в условиях ограничений, накладываемых как на приемистость нагнетательных скважин, так и на дебит жидкости добывающих скважин. Общую совокупность ограничений составляют суточная закачка воды и добыча жидкости, а дифференциальную – максимальные и минимальные приемистости и дебиты жидкости по скважинам.

Результатом решения оптимизационной задачи являются, во-первых, комбинация режимов работы всех нагнетательных скважин, отвечающая заданным ограничениям и обеспечивающая максимизацию целевого показателя суточной добычи нефти, во-вторых, потенциальные уровни добычи нефти, соответствующие модели ограничений и оптимальным режимам нагнетательных скважин, и в-третьих, оптимальные дебиты жидкости скважин, обеспечивающие расчетные отборы нефти.

В ходе решения оптимизационной задачи будет получено некоторое решение, оценить эффективность которого можно, сопоставляя текущие и оптимальные режимы закачки. Элемент заводнения, в число которого входят добывающая скважина и влияющие на нее нагнетательные, считается оптимизированным в том случае, если входящие в него нагнетательные скважины работают в своих оптимальных режимах.

Оценить достоверность полученных в ходе прокси-моделирования результатов можно в сравнении с результатами эффективности адаптации гидродинамической модели, поскольку она более содержательна с физической точки зрения.

Итак, предлагается следующий алгоритм действий при обосновании перевода добывающей скважины в систему ППД:

### *1. Подготовка данных.*

На начальном этапе прокси-моделирования необходимо тщательно обработать исходные данные: исключить из динамики показателей выбросы, дни проведения геолого-технических мероприятий, «сгладить» результирующую динамику экстраполяционными методами (метод трендов, метод Савицкого-Голея, вейвлет-сглаживание и др.).

### *2. Адаптация прокси-модели на исторические показатели разработки.*

По каждому сформированному заранее элементу заводнения производится обучение нейронной сети, называемое в контексте данной работы адаптацией прокси-модели, по дебиту жидкости и доле нефти. В результате будет получена многомерная функция взаимосвязей, создающая возможность для решения оптимизационных задач разного рода, в том числе и для максимизации добычи нефти.

### *3. Определение необходимых объемов закачки в нагнетательные скважины посредством решения оптимизационной задачи по полученной прокси-модели.*

На основе обученной нейронной сети определяются значения приемистостей нагнетательных скважин таким образом, чтобы суточная добыча нефти при заданных ограничениях была максимальной.

### *4. Подбор скважины-кандидата под перевод в ППД.*

Подбор осуществляется в соответствии со следующими критериями:

- в районе скважины-кандидата должно наблюдаться низкое пластовое давление;
- тренд по пластовому давлению в районе скважины-кандидата негативный;
- вблизи скважины-кандидата наблюдается высокая плотность расположения добывающих скважин.

### *5. Составление группы исследования.*

Такая группа включает в себя скважину-кандидата, влияющие на нее нагнетательные скважины, составляющие единый элемент заводнения с

кандидатом, и добывающие скважины, расположенные в пределах радиуса влияния  $r = \frac{\sum_{i=1}^n r_i}{n}$  ( $r_i$  – расстояние от  $i$ -ой исследуемой нагнетательной скважины до скважины-кандидата,  $n$  – количество нагнетательных скважин). На нагнетательных скважинах будет имитироваться процесс закачки, то есть между ними будет поровну распределено значение потенциальной приемистости скважины-кандидата, а по добывающим будет оцениваться эффект от перевода.

*6. Решение локальной оптимизационной задачи.*

Локальная оптимизационная задача будет решаться в условиях бездействия скважины-кандидата, а ограничением суммарной закачки будет являться совокупность режимов, полученных при решении первичной оптимизационной задачи, и потенциальной приемистости скважины-кандидата.

*7. Определение эффективности перевода скважин в ППД.*

Эффект оценивается как разница между суммарным приростом суточной добычи нефти добывающих скважин из группы исследования, полученным в результате решения локальной оптимизационной задачи, и текущим значением суточной добычи нефти скважины-кандидата.

Предполагается, что таким образом можно определить потенциальный эффект от перевода скважины в систему ППД.



## ЗАКЛЮЧЕНИЕ

Тема оптимизации каких-либо процессов находит широкий отклик практически во всех сферах жизнедеятельности: выбирая кратчайший и минимально затратный по времени путь можно значительно сэкономить на производстве. Автоматизация в развитии тех или иных вопросов нефтегазового инжиниринга приводит к возможности реализовывать многозадачные проекты, что в свою очередь влечет за собой повышение эффективности работы предприятий. Прокси-моделирование является одним из таких ресурсов.

В ходе выполнения данной работы была достигнута поставленная цель – создан и протестирован метод, позволяющий без составления сложных гидродинамических моделей проводить расчеты по формированию системы поддержания пластового давления.

Успешный результат фильтрации суточных замеров дебита жидкости и доли нефти от шумов и эффектов о проведения ГТМ стал базой для обучения нейронной сети, качество адаптации составило 87%. На основе полученной прокси-модели была решена оптимизационная задача определения оптимальных объемов закачки рабочего агента в пласт Альфа реального месторождения. Результат решения показал, что при корректировании действующей системы поддержания пластового давления суточная добыча нефти могла бы достигнуть 725 т/сут, что на 30% больше текущего значения. Таким образом, полученные режимы работы нагнетательных скважин можно считать удовлетворительными для дальнейшего анализа.

Выбранная для анализа эффективности перевода в нагнетательный фонд скважина удовлетворила необходимым требованиям: текущее пластовое давление определено ниже начального на 37%, был выявлен тренд на снижение пластового давления, расположение скважины-кандидата дало возможность высоко оценить плотность скопления вокруг нее количества добывающих скважин.

Была рассчитана потенциальная приемистость переводимой скважины с учетом приемистостей влияющих на нее нагнетательных скважин, она составила 200 м<sup>3</sup>/сут.

Эффективность перевода добывающей скважины в нагнетательный фонд оценивалась по добывающим скважинам, расположенным от скважины-кандидата на расстоянии среднего радиуса между всеми парами скважин – 736м.

Для определения того, насколько качественно сработал предложенный алгоритм, использовалась разработанная в программном комплексе tNavigator гидродинамическая модель пласта Альфа.

На основе выполненных расчетов прокси- и гидродинамического моделирования пласта Альфа показано, что предложенная методика позволяет выполнять базовые расчеты при формировании системы поддержания пластового давления: эффект по дебиту нефти после перевода скважины №887, определенный по прокси модели, составил +2.2 т/сут, по ГДМ – +2.6 т/сут. Расхождение между полученными данными составляет 18%, что может говорить о непротиворечивости полученных данных.

Тестирование представленной методики проводилось в рамках исследовательского проекта, предложенного к внедрению в ООО «ТИНГ».

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Бриллиант Л.С., Комягин А.И., Блящук М.И., Цинкевич О.В., Журавлева А.А. Способ оперативного управления заводнением пластов, RU2015156293A, 2017 г.
2. Пер. с польского И.Д. Рудинского, Нейронные сети для обработки информации. - М.: Финансы и статистика, 2002, 344 с.
3. Иваненко Б.П. Нейросетевое имитационное моделирование нефтяных месторождений и гидрогеологических объектов. – Томск: Изд-во Дом ТГУ, 2014. – 188 с.
4. Пантелеев А.В., Летова Т.А., Методы оптимизации в примерах и задачах. - М.: Высш. шк., 2005, 544 с.
5. Желтов Ю.П., Разработка нефтяных месторождений: Учеб. для вузов. - 2-е изд., перераб. и доп.- М.: ОАО «Издательство «Недра», 1998, 365 с.
6. Костюченко С.В., Ямпольский В.З. Мониторинг и моделирование нефтяных месторождений. Томск: Изд-во НТЛ, 2000. 246 с.
7. Рейзлин В. И. Численные методы оптимизации: учебное пособие / В.И. Рейзлин; Томский политехнический университет. – Томск: Изд-во Томского политехнического университета, 2011 – 105 с.
8. Попов И.П. Максимов М.Н. Анализ эффективности системы заводнения и причины формирования трудно извлекаемых запасов // Европейские прикладные науки. Штутгарт, 2012. №1. С.13-16.
9. Мину М. Математическое программирование. Теория и алгоритмы. - М.: Наука, 1990. - 486 с.
10. Захарова Е.Ф., Пашанина О.Д., Тронов В.П. Совершенствование системы поддержания пластового давления на Березовском месторождении // Электронный научный журнал «Нефтегазовое хозяйство» 09/2003, с. 68-70

11. Jaber, A.K., Al-Jawad, S.N. & Alhuraishawy, A.K. A review of proxy modeling applications in numerical reservoir simulation. *Arab J Geosci* 12, 701 (2019).
12. A. Bao, E. Gildin, H. Zalavadia. Development Of Proxy Models For Reservoir Simulation By Sparsity Promoting Methods And Machine Learning Techniques. Conference Proceedings, ECMOR XVI - 16th European Conference on the Mathematics of Oil Recovery, Sep 2018, Volume 2018, p.1 – 14.
13. Ng, C.S.W., Jahanbani Ghahfarokhi, A., Nait Amar, M. et al. Smart Proxy Modeling of a Fractured Reservoir Model for Production Optimization: Implementation of Metaheuristic Algorithm and Probabilistic Application. *Nat Resour Res* 30, 2431–2462 (2021).
14. Robert E. Uhrig, “Introduction to Artificial Neural Networks”, *IEEE Transactions on Industrial Electronics, Control, and Instrumentation*, vol. 1, pp. 33-37, 1995.
15. Yoshua Bengio, Patrice Simard, and Paolo Frasconi. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2):157–166, 1994