

Разработка алгоритма управления процессами фильтрации в пористой среде с использованием нейронных операторов

Д. Д. Сирота¹, С. Е. Душин²

¹Санкт-Петербургский государственный университет

ds11011@yandex.ru

²Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В. И. Ульянова (Ленина)

Аннотация. Численное моделирование фильтрации флюидов в пористой среде сопряжено с высокой вычислительной сложностью, что существенно ограничивает применение алгоритмов оптимального управления данными процессами. Вместе с тем эффективное управление фильтрацией имеет важное практическое значение для таких областей, как нефтегазодобыча, эксплуатация подземных хранилищ природного газа (ПХГ) и геологическое хранение диоксида углерода. В данной работе предложен подход, позволяющий преодолеть вычислительные ограничения классических численных методов за счет использования современных методов глубокого обучения. Основная цель исследования заключается в разработке алгоритма оптимального управления, основанного на аппроксимации нелинейных уравнений фильтрации с помощью нейронных операторов. Обученные модели позволяют существенно снизить вычислительные затраты при решении задач управления. В работе представлены результаты валидации предложенного подхода на модельной задаче закачки диоксида углерода в пласт, подтверждающие его вычислительную эффективность и перспективность практического применения на реальных объектах.

Ключевые слова: глубокое обучение; искусственный интеллект; нейронные операторы; системы поддержки принятия решений; оптимальное управление; процессы фильтрации в пористой среде

I. ВВЕДЕНИЕ

Эффективность алгоритмов оптимального управления процессами нестационарной фильтрации в пористой среде во многом определяется точностью и скоростью расчетов моделей динамики системы. Однако традиционные численные методы (например, метод конечных объемов), применяемые в современных геолого-гидродинамических симуляторах, обладают высокой вычислительной сложностью, что ограничивает их использование в задачах оптимального управления реальными объектами месторождений нефти и газа; подземного хранения газа и систем геологического хранения CO₂.

Для преодоления этих ограничений представляется перспективным применение методов глубокого обучения. Однако значительная часть исследований в данной области посвящена построению отображений между конечномерными пространствами [1, 2]. Аппроксимация решений нелинейных уравнений нестационарной фильтрации представляет собой принципиально иную задачу. Данные уравнения, описываемые системами дифференциальных уравнений

в частных производных (ДУЧП), требуют построения операторов между бесконечномерными функциональными пространствами [3]. Хотя теоремы универсальной аппроксимации [4, 5] и работы [6–8] обосновывают принципиальную возможность аппроксимации таких операторов глубокими нейронными сетями, практическая эффективность существенно зависит от выбора архитектуры. Например, полносвязные нейронные сети показывают значительно более низкое качество в задачах компьютерного зрения по сравнению с широко используемыми сверточными архитектурами [2]. Применение методов глубокого обучения для моделирования фильтрационных процессов также осложняется высокой вычислительной стоимостью генерации обучающих данных, требующей многочисленных запусков традиционных гидродинамических симуляторов.

Одним из перспективных подходов глубокого обучения, является построение и обучение нейронных операторов, которые представляют собой отображения между функциональными пространствами [9–11]. В отличие от традиционных нейросетевых архитектур, они обладают свойством инвариантности к сетке дискретизации, требуют лишь однократного обучения и показывают высокую точность в задачах аппроксимации решений ДУЧП, включая уравнения фильтрации.

Несмотря на активное развитие методов, основанных на обучении нейронных операторов, их применение для задач управления процессами фильтрации остается малоизученным. В настоящей работе разработан алгоритм управления, использующий нейронные операторы в качестве моделей динамики системы. Разработанный подход протестирован на задаче управления закачкой CO₂ в пласт [12].

II. МАТЕМАТИЧЕСКАЯ МОДЕЛЬ МНОГОФАЗНОЙ ФИЛЬТРАЦИИ В ПОРИСТОЙ СРЕДЕ

Рассмотрим задачу двухфазной фильтрации CO₂ и пластовой воды. Углекислый газ и вода не смешиваются, но имеют взаимную растворимость. Общая форма уравнений такого многофазного потока для компоненты $\eta = \text{CO}_2$ и пластовой воды может быть записана следующим образом (1–3) [12]:

$$\frac{\partial \left(\varphi \sum_p S_p \rho_p X_p^{\text{CO}_2} \right)}{\partial t} = -\nabla \cdot \left[\mathbf{F}^{\text{CO}_2} |_{adv} + \mathbf{F}^{\text{CO}_2} |_{dif} \right] + q^{\text{CO}_2}, \quad (1)$$

$$\frac{\partial(\phi \sum_p S_p \rho_p X_p^{water})}{\partial t} = -\nabla \cdot [\mathbf{F}^{water}_{adv} + \mathbf{F}^{water}_{dif}], \quad (2)$$

$$\mathbf{F}^\eta|_{adv} = \sum_p X^\eta \mathbf{F}_p = \sum_p X^\eta \left(-k_{r,p} \rho_p (\nabla P_p - \rho_p \mathbf{g}) \right). \quad (3)$$

Здесь ϕ – пористость, S_p – насыщенность фазы p , а X_p^η – массовая доля компонента η в фазе p , $\mathbf{F}_p$ – закон Дарси для многофазного потока, k – абсолютная проницаемость, $k_{r,p}$ – относительная проницаемость фазы p , которая нелинейно зависит от насыщенности S_p , μ_p – вязкость фазы p , которая зависит от давления P_p , а $\mathbf{g}$ – ускорение свободного падения, ρ_p – плотность фазы.

III. АРХИТЕКТУРА МОДЕЛИ НЕЙРОННОГО ОПЕРАТОРА

В данной работе рассматривается модель, основанная на методе [12], который представляет собой модифицированный нейронный оператор Фурье, с добавлением операторов свёрточной нейронной сети U-Net для повышения выразительности за счет обработки высокочастотной информации, которая не улавливается базисом Фурье (рис. 1).




Рис. 1. (а) Архитектура модели: $x(x)$ – входные данные, P и Q – полносвязные слои, $u(x)$ – выход модели; (б) Слой Фурье: F – преобразование Фурье, R представляет собой параметризацию в пространстве Фурье, F^{-1} – обратное преобразование Фурье, W – нелинейное смещение, σ – функция активации; (в) Модифицированный слой Фурье: U – оператор U-Net, остальные обозначения имеют то же значение, что и в слое Фурье

Данный метод показал высокую эффективность при моделировании процессов закачки двуокиси углерода в пласт.

IV. КОНФИГУРАЦИЯ ДАННЫХ И ИДЕНТИФИКАЦИЯ МОДЕЛИ ОБЪЕКТА УПРАВЛЕНИЯ

В рамках данной работы использован открытый набор данных из [12], рассчитанный на численном симуляторе для процесса закачки в пласт сверхкритического диоксида углерода. Газ закачивается с постоянным расходом в радиально-симметричную систему $x(r, z)$ через вертикальную нагнетательную скважину радиуса 0,1 м. Толщина пласта колеблется от 12,5 до 200 м. Радиус пласта составляет 100 тыс. м. Границы пласта непроницаемы. Горизонт моделирования – 30 лет (24 временных шага с экспоненциальным укрупнением). Расход закачиваемого газа варьируется от 0,2 до 2 млн тонн в год. В состав входных данных входит проницаемость, пористость, коэффициент анизотропии, толщина пласта, область перфорации, массовый расход углекислого газа при

закачке, начальное пластовое давление, температура пласта, остаточная водонасыщенность, а также вспомогательные признаки. В качестве выходных данных выступает перепад пластового давления в каждой точке пласта по пространству и времени. Полный набор данных состоит из 5500 расчетов.

При постановке численных экспериментов по идентификации модели объекта в данной работе использована модель, основанная на методе U-FNO [12] с числом мод Фурье, ограниченным 10 (64,2 млн параметров). Статистические характеристики точности указанной модели на тестовом наборе данных приведены на рис. 2 и в табл. 1.




Рис. 2. Гистограмма распределения ошибок обученной модели на тестовом наборе данных

ТАБЛИЦА I. СТАТИСТИЧЕСКИЕ ХАРАКТЕРИСТИКИ ОШИБОК ОБУЧЕННОЙ МОДЕЛИ

Среднее (бар)	Стандартное отклонение (бар)
-0,066	0,34

Обученная модель способна достаточно точно воспроизводить динамику пластового давления в процессе закачки диоксида углерода. Сравнение динамики распределения поля пластового давления, предсказанной нейронным оператором и численным симулятором на тестовых данных представлено на рис. 3.




Рис. 3. Визуализация перепада давления, рассчитанного на численном симуляторе, нейронном операторе и абсолютной ошибки на тестовом образце (временной шаг 16/24)

Выходные данные обученного нейронного оператора выглядят гладкими и воспроизводят глобальные и локальные особенности моделируемого процесса закачки диоксида углерода.

V. РАЗРАБОТКА АЛГОРИТМА УПРАВЛЕНИЯ

В рамках данной работы объектом управления является процесс закачки газа в подземный пласт, управляющее воздействие представляет собой массовый расход закачки газа q через вертикальную скважину. Целью управления является поиск максимально допустимого значения q при поддержании выходной переменной (перепада давления ΔP) ниже заданного порога ΔP_{max} на всем пространственно-временном горизонте для соблюдения геологических ограничений.

При такой постановке задача оптимального управления может быть записана следующим образом (4–5):

$$\max_{q(t)} J[q], \quad J[q] = \int_0^T q(t) dt, \quad (4)$$

при условии:

$$\begin{cases} \Delta P(x, t; q) \leq \Delta P_{\max}, & \forall x \in \Omega, \forall t \in [0, T], \\ q_{\min} \leq q(t) \leq q_{\max}, & \forall t \in [0, T]. \end{cases} \quad (5)$$

Здесь $q(t)$ – массовый расход закачки (управляющее воздействие), $\Delta P(\mathbf{x}, t) = P(\mathbf{x}, t) - P_0(\mathbf{x})$ – перепад давления относительно начального, $\Omega \subset \mathbb{R}^d$ – пространственная область пласта.

Введем составной целевой функционал, объединяющий цель управления и функцию штрафов за нарушение ограничений (6):

$$J(\mathbf{q}) = \underbrace{\sum_{i=0}^{T-1} q_i}_{\text{Расход}} - \lambda \cdot \underbrace{\sum_{i=1}^T \sum_j f(\Delta P_i(\mathbf{x}_j) - \Delta P_{\max})}_{\text{Штрафная функция}}, \quad (6)$$

где $\lambda > 0$ – коэффициент регуляризации, f – гладкая функция штрафа, $\{\Delta P_i(\mathbf{x}_j)\}_{i=1}^T = \mathcal{G}(\mathbf{q})$ – отклик системы, рассчитанный с помощью нейронного оператора $\mathcal{G}$ в каждой точке j моделируемого пласта в момент времени i .

Алгоритм управления.

Инициализация: λ , $\Delta P_{\max}$, $q_{\min}$, $q_{\max}$, α – размер шага градиентного спуска; $\mathbf{q}^{(0)}$ – начальное управление, $\mathcal{G}_\theta$ – обученная модель нейронного оператора.

Шаги алгоритма. Для $k = 0, 1, \dots, N_{\max}$:

1. Моделирование давления:

$$\{\Delta P_i^{(k)}(\mathbf{x}_j)\} \leftarrow \mathcal{G}_\theta(\mathbf{q}^{(k)});$$

2. Вычисление функционала:

$$J^{(k)} = \sum_{i=0}^{T-1} q_i^{(k)} - \lambda \sum_{i,j} f(\Delta P_i^{(k)}(\mathbf{x}_j) - \Delta P_{\max});$$

3. Шаг градиентного спуска:

$$\mathbf{q}^{(k+1)} \leftarrow \left(\mathbf{q}^{(k)} - \alpha \cdot \nabla_{\mathbf{q}} J^{(k)} \right)$$

Возврат результата:

$$\mathbf{q}^* = \mathbf{q}^{(k+1)}$$

Градиент целевого функционала по управлению вычисляется посредством автоматического дифференцирования, что возможно благодаря дифференцируемости модели нейронного оператора и гладкости введенной штрафной функции, что обеспечивает точное и эффективное вычисление производных без необходимости численной аппроксимации и позволяет применять методы градиентной оптимизации для решения задачи оптимального управления.

VI. РЕЗУЛЬТАТЫ ЧИСЛЕННЫХ ЭКСПЕРИМЕНТОВ

В данном разделе приведены результаты численных экспериментов по оптимизации управляющих воздействий q с использованием разработанного в данной работе алгоритма.

В качестве примера взят образец сценария из тестовой выборки, в котором пластовая депрессия достигает 75 бар (максимальное значение). Далее, при тех же исходных данных (пластовые свойства и начальное давление) произведена оптимизация расхода газа, при условии, что предельная пластовая депрессия составляет 60 бар.

На рис. 4 приведен график значения функционала в процессе итераций оптимизационного алгоритма.




Рис. 4. График значения оптимизируемого функционала

Отметим, что поиск решения занимает порядка 20 секунд на рабочей станции с GPU NVIDIA GeForce RTX 3090, что делает этот метод эффективным с точки зрения вычислительных затрат, при условии выполнения 200 итераций градиентного спуска.

На рис. 5 представлено сравнение гистограмм распределения перепадов давления между базовым и оптимизированным сценариями.




Рис. 5. Гистограмма распределения перепадов давления

Показано, что разработанный алгоритм управления обеспечивает нахождение оптимальных значений управляющих воздействий с учетом заданных ограничений.

VII. ЗАКЛЮЧЕНИЕ

Разработан алгоритм управления процессами фильтрации в пористой среде с использованием нейронных операторов. На примере задачи аппроксимации процесса закачки сверхкритического диоксида углерода в пласт показано, что данный метод обладает высокой вычислительной эффективностью.

СПИСОК ЛИТЕРАТУРЫ

- [1] LeCun Y, Bengio Y, Hinton G. Deep learning. Nature 2015; 521: 436–444. <https://doi.org/10.1038/nature14539>.
- [2] Goodfellow I, Bengio Y, Courville A. Deep learning. Cambridge, Massachusetts: The MIT Press, 2016. 775 p.
- [3] Aziz K, Settari A. Petroleum reservoir simulation. London New York: Applied science publ, 1979. 497 p.
- [4] Cybenko G. Approximation by superpositions of a sigmoidal function. Math Control Signals Syst 1989; 2: 303–314. <https://doi.org/10.1007/BF02551274>.
- [5] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators. Neural Netw 1989; 2: 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8).
- [6] Chen T, Chen H. Approximations of continuous functionals by neural networks with application to dynamic systems. IEEE Trans Neural Netw 1993; 4: 910–918. <https://doi.org/10.1109/72.286886>.
- [7] Chen T, Chen H. Approximation capability to functions of several variables, nonlinear functionals, and operators by radial basis function neural networks. IEEE Trans Neural Netw 1995; 6: 904–910. <https://doi.org/10.1109/72.392252>.
- [8] Chen T, Chen H. Universal approximation to nonlinear operators by neural networks with arbitrary activation functions and its application to dynamical systems. IEEE Trans Neural Netw 1995; 6: 911–917. <https://doi.org/10.1109/72.392253>.
- [9] Lu L, Jin P, Karniadakis GE. DeepONet: Learning nonlinear operators for identifying differential equations based on the universal approximation theorem of operators. Nat Mach Intell 2021; 3: 218–229. <https://doi.org/10.1038/s42256-021-00302-5>.
- [10] Li Z, Kovachki N, Azizzadenesheli K, et al. Neural Operator: Graph Kernel Network for Partial Differential Equations. Epub ahead of print 2020. <https://doi.org/10.48550/ARXIV.2003.03485>.
- [11] Kovachki N, Li Z, Liu B, et al. Neural Operator: Learning Maps Between Function Spaces. Epub ahead of print 2021. <https://doi.org/10.48550/ARXIV.2108.08481>.
- [12] Wen G, Li Z, Azizzadenesheli K, et al. U-FNO—An enhanced Fourier neural operator-based deep-learning model for multiphase flow, Advances in Water Resources, 2022, <https://doi.org/10.1016/j.advwatres.2022.104180>.