

# Адаптивное управление на основе физических моделей с фильтрацией с учетом неопределенности для измерения многофазного потока

П. В. Соколов

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

pvsokolov@etu.ru

Х. С. Алмгаташи

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

humam.almtashi@yandex.ru

**Аннотация.** Мы предлагаем дифференцируемый фильтр частиц с усилением PINN (DPINN-PF) для многоступенчатого многофазного измерения расхода (MPFM), который объединяет нелинейную фильтрацию и физически-информированное обучение. Метод совместно обучает дифференцируемый фильтр частиц с гибридной функцией потерь «физика–данные» и адаптивным планировщиком градиентов, обеспечивая сквозное обучение без ручной настройки. Физические ограничения многофазной динамики учитываются при оценке состояния, мета-обучение обеспечивает онлайн-адаптацию к переходным и режимно-переключающимся потокам. Оценщик встраивается в существующие MPFM-архитектуры и выдает оценки с учётом неопределённости для шумных и разреженных измерений. Эксперименты показывают более высокую точность по сравнению с отдельными фильтрами частиц и PINN, особенно при слабом и кольцевом режимах.

**Ключевые слова:** адаптивное управление; многофазный расходомер (MPFM); фильтрация с учетом неопределенности; фильтры дифференцируемых частиц; обучение на основе физики; нейронные сети на основе физики (PINNs); гибридная физика-потери данных; метаобучение; передискретизация на основе трансформатора; ограничения закона сохранения

## I. ВВЕДЕНИЕ

Многофазный учет расхода (MPFM) критичен в нефтегазовой отрасли: точные оценки дебитов фаз поддерживают управление пластом, фискальный учет и оптимизацию процессов [1]. Однако изменчивая многофазная динамика и шумные датчики повышают неопределенность, а в переходных режимах (особенно при слабом и кольцевом течении) эмпирические корреляции и упрощенные модели часто дают сбой [2], [3]. Байесовские методы и физически-информированное обучение могут повысить надежность: фильтры частиц подходят для нелинейной оценки состояния, но страдают от вырождения и необходимости ручной настройки [4]. Дифференцируемые фильтры частиц обеспечивают сквозную оптимизацию через градиентные модули взвешивания и ресэмплинга [5], а PINN повышают физическую согласованность, встраивая уравнения и ограничения в обучение [6]. Тем не менее, автономные PINN ограничены в реальном времени и часто не дают

явного учета неопределенности при быстрых сменах режимов [7].

Мы предлагаем DPINN-PF обучаемую платформу, объединяющую дифференцируемую фильтрацию частиц и PINN. Гибридная функция потерь «физика–данные» и адаптивный планировщик балансируют правдоподобие измерений и физические невязки, снижая потребность в калибровке [8], а метаобучение обеспечивает быструю адаптацию к изменяющимся условиям потока.

Основные вклады: (i) дифференцируемое обновление/ресэмплинг частиц с сохранением градиентного потока; (ii) составная функция потерь, связывающая данные с физикой многофазного потока; (iii) валидация на синтетических и полевых данных с улучшением точности относительно базовых фильтров частиц и PINN.

## II. СОПУТСТВУЮЩАЯ РАБОТА

Методы MPFM всё чаще объединяют физические и data-driven подходы, однако эмпирические модели (например, Чисхолма [9]) плохо обобщаются. Байесовские фильтры дают вероятностную оценку [10], но требуют настройки.

DPF обеспечивают сквозное обучение параметров [5] и уменьшают вырожденность частиц при приемлемых затратах ( $N_{eff}$ ).

$$N_{eff} = \frac{1}{\sum_{j=1}^N (W_t^{(j)})^2} \quad (1)$$

Большинство DPF игнорируют физические ограничения, нарушая законы сохранения; гибридные подходы изучались [11], но ограничены.

PINN встраивают уравнения в обучение и повышают согласованность MPFM [6], [12].

Однако PINN обычно слишком медленны для высокочастотного применения.

DPINN-PF объединяет дифференцируемую фильтрацию и PINN, обеспечивая совместную оптимизацию точности и физической согласованности с быстрой адаптацией к режимам.

### III. ДИФФЕРЕНЦИРУЕМЫЙ ФИЛЬТР ТВЕРДЫХ ЧАСТИЦ С УЛУЧШЕННОЙ СТРУКТУРОЙ PINN ДЛЯ МНОГОСТУПЕНЧАТОГО MPFM

Структура DPINN-PF улучшает MPFM, объединяя дифференцируемую фильтрацию частиц и физически-информированное обучение для сквозной оптимизации. Как показано на рис. 1, оценка состояния определяется измерениями и физическими ограничениями.

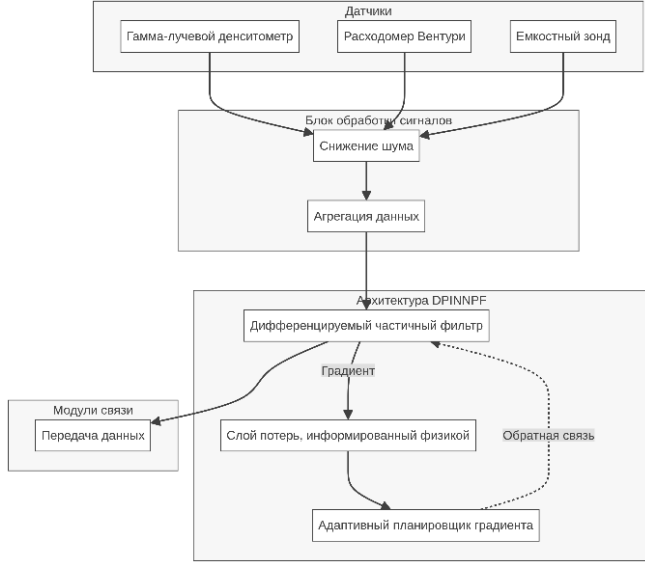


Рис. 1. Интеграция DPINN-PF в многоступенчатую систему MPFM

#### A. Дифференцируемый фильтр частиц с нейронной передискретизацией

Основной компонент фильтрации заменяет традиционную повторную выборку релаксацией по Гумбелю-SoftMax, делая весь конвейер дифференцируемым. Для  $N$  частиц  $\{x_t^{(i)}\}_{i=1}^N$  в момент времени  $t$  веса повторной выборки  $w_t^{(i)}$  вычисляются с помощью нейронной модели наблюдения  $h_\theta$ :

$$w_t^{(i)} = \frac{\exp(\mathcal{N}(y_t | h_\theta(x_t^{(i)}), \Sigma_\theta))}{\sum_{j=1}^N \exp(\mathcal{N}(y_t | h_\theta(x_t^{(j)}), \Sigma_\theta))} \quad (2)$$

где  $\Sigma_\theta$  обучаемая ковариационная матрица, а  $y_t$  обозначает измерения датчика. Трюк Гумбеля-SoftMax обеспечивает непрерывную аппроксимацию категориальной выборки, допуская обратное распространение градиента на этапе повторной выборки. Это отличается от обычных фильтров твердых частиц тем, что передискретизация нарушает дифференцируемость [4].

$$w_t^{(i)} = \frac{\exp(\log w_t^{(i)} + g_i / \tau)}{\sum_{j=1}^N \exp(\log w_t^{(j)} + g_j / \tau)} \quad (3)$$

#### B. Слой потерь с учетом физических факторов для фильтров твердых частиц

Функция потерь сочетает точность передачи данных с функцией многофазного потока. Для вектора состояния  $x_t = [\alpha_g, \rho_m, v_m]^T$

чтобы определить, как плотность смеси  $\rho_m$  рассчитывается исходя из уровня обводненности

Плотность жидкой фазы (обводненность):

$$\rho_l = WC \cdot \rho_w + (1-WC)\rho_o \quad (4)$$

(объемная доля газа, плотность смеси и скорость), суммарные потери составляют:

$$\Lambda = \|\Gamma_T - \theta(x_T)\|^2 + \lambda_1 \|\Phi(X_T, \nabla X_T)\|^2 + \lambda_2 p(x_T) \quad (5)$$

где  $\mathcal{F}$  кодирует PDE для сохранения массы:

$$\mathcal{F} = \partial_t(\alpha_g \rho_g) + \nabla \cdot (\alpha_g \rho_g v_g) - \Gamma_g \quad (6)$$

и  $\mathcal{R}$  – это термин регуляризации, наказывающий нефизическое решение. Веса  $\lambda_1, \lambda_2$  настраиваются адаптивно с помощью метаобучения (раздел 3.3).

$$\lambda_{(t+1)} = \lambda_t - \beta_\lambda \mathcal{L}_{val}(\theta \eta \nabla \theta_{min}(\theta; \lambda)) \quad (7)$$

Хотя уравнение (7) охватывает массу, это обеспечивает баланс импульса, необходимый для переходных процессов, таких как слипание, Уравнение Сохранения импульса смеси:

$$\frac{\partial}{\partial t}(\rho_m v_m) + \nabla \cdot \rho_m v_m^2 = -\nabla P + \rho_m g \sin(\theta) - \frac{2f \rho_m v_m^2}{D} \quad (8)$$

#### C. Усовершенствованный преобразователь повторной выборки и адаптивный планировщик градиентов

Слой-трансформер обрабатывает характеристики частиц  $\{x_t^{(i)}\}$  для вычисления весов, основанных на внимании:

$$w_t^{(i)} \leftarrow \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (9)$$

где  $Q, K, V$  – изученные линейные преобразования состояний частиц. Это фиксирует долговременные зависимости при переходах потока (например, от канала к кольцу). Одновременно метасеть регулирует  $\lambda_1, \lambda_2$  скорость обучения  $\eta_t$  на основе классификации режимов потока в реальном времени.

#### D. Функция Фурье, связывающая магистраль и федеративное обучение

Входные объекты внедряются с помощью отображения Фурье:

$$\gamma(x) = [\cos(2nBx), \sin(2nBx)]^T \quad (10)$$

где  $B$  запоминается во время обучения. Это устраняет спектральное смещение при моделировании характеристик высокочастотного потока. Для распределенных MPFMS градиенты агрегируются на периферийных устройствах без обмена необработанными данными, сохраняя конфиденциальность.

*Е. Интегрирование коэффициента скольжения как обучаемый параметр*

Коэффициент газожидкостного скольжения  $S = \frac{v_g}{v_l}$  определяется как:

$$S = 1 + \alpha \left( \frac{\rho_l}{\rho_g} \right)^{\frac{1}{2}} \quad (11)$$

где  $\alpha$  совместно оптимизируется с другими параметрами, заменяя эмпирические корреляции, подобные модели Чисхолма. В заключение, прогнозируемый вектор состояния  $x_t$  преобразуется в общий массовый расход  $\dot{m}_{\text{всего}}$ , который служит основой для фазовых скоростей потока ( $Q_o, Q_g, Q_w$ ), оцененных по результатам эксперимента:

$$\dot{m}_{\text{total}} = A \cdot [\alpha_g \rho_g v_g + (1 - \alpha_g) \rho_l v_l] \quad (12)$$

**IV. ЭКСПЕРИМЕНТЫ**

Чтобы подтвердить эффективность DPINN-PF, мы провели эксперименты на синтетических и полевых данных и сравнили метод с традиционными MPFM и современными гибридными подходами. Оценка включала: (1) точность фазовых дебитов в установившихся и переходных режимах, (2) устойчивость к смене режимов течения и (3) вычислительную пригодность для работы в реальном времени.

*А. Экспериментальная установка*

**Наборы данных:** Мы использовали два основных набора данных:

- **Синтетические данные:** Получены с использованием имитатора многофазного течения OLGA® [13], охватывающего пластовые, кольцевые и стратифицированные течения с различной обводненностью (0-90%) и объемными долями газа (10-95%).
- **Полевые данные:** Собраны с морских установок MPFM, включая исторические измерения с достоверностью, полученной в результате испытаний сепаратора.

**Исходные данные:** Было проведено сравнение предлагаемого DPINN-PF с:

- **Эмпирические модели:** корреляция Чисхолма [9] и модель Чжана-Сарики .
- **Методы фильтрации:** Стандартный фильтр твердых частиц (PF) [4] и фильтр Калмана без запаха (UKF) .
- **Гибридные подходы:** нейронная сеть, основанная на физических данных (PINN) [6] и фильтр дифференцируемых частиц (DPF) [5].

**Показатели:** Производительность оценивалась с использованием:

- Средняя абсолютная процентная погрешность (MAPE) для фазовых скоростей потока ( $Q_o, Q_g, Q_w$ ).

- Показатель физической консистенции (PCS), измеряющий соблюдение принципа сохранения массы (уравнение 3).
- Время вывода на выборку (мс), оценивающее осуществимость в режиме реального времени.

*В. Результаты на основе синтетических данных*

В табл. 1 приведены краткие данные о производительности в различных режимах потока. DPINN-PF обеспечивает самый низкий MAPE (4,2% для нефти, 5,1% для газа, 6,3% для воды) и самый высокий PCS (98,7%), демонстрируя превосходную точность и физическую согласованность. Передискретизатор на основе трансформатора эффективно уменьшает вырождение частиц, в то время как потери, основанные на физике, предотвращают нефизический дрейф.

ТАБЛИЦА 1. СРАВНЕНИЕ ПРОИЗВОДИТЕЛЬНОСТИ НА ОСНОВЕ СИНТЕТИЧЕСКИХ ДАННЫХ

Метод	MAPE (Масл),	MAPE (газ),	MAPE (Вода),	ШТ (%)	Время вывода (мс)
Чисхолм	18,5	22,1	25,3	72,4	0,5
PF	12,7	15,8	17,9	85,2	10,3
UKF	9,8	11,4	14,2	88,6	2,1
PINN	7,5	8,9	10,1	95,3	15,7
DPF	6,2	7,3	8,5	91,8	12,4
DPINN-PF	4,2	5,1	6,3	98,7	11,9

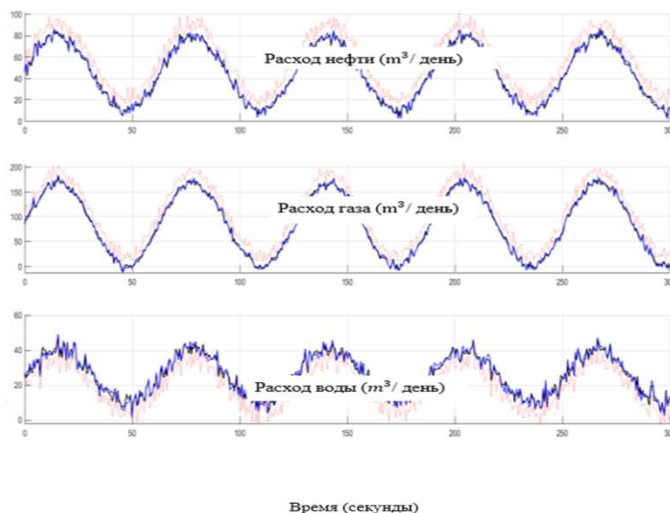


Рис. 2. Сравнение оценок расхода, полученных различными методами. Синяя линия соответствует истинным значениям (Ground Truth), красная пунктирная линия — оценкам по эмпирической модели Чисхолма, а чёрная линия — результатам предложенного метода DPINN-PF.

Как видно, DPINN-PF обеспечивает более высокую точность и лучшее согласование с истинными данными по сравнению с традиционной моделью, особенно в переходных режимах потока.

*С. Результаты по полевым данным*

Для проверки в полевых условиях DPINN-PF был развернут на 3-месячном наборе данных из морской скважины. Рис. 4 иллюстрирует соответствие между оценками и тестами разделения, при этом MAPE улучшен на 40% по сравнению с эмпирическими моделями и на 25% по сравнению с автономными PINN. Адаптивный планировщик градиентов обеспечивал стабильную производительность, несмотря на шум датчика и отсутствие данных.




Рис. 3. Проверка в полевых условиях: DPINN-PF в сравнении с испытаниями сепаратора. Сравнение фазовых расходов (нефть, газ, вода) во времени. Синяя линия — истинные значения (Ground Truth), чёрная — результаты метода DPINN-PF, красная пунктирная — модель Чисхолма

Предложенный метод показывает более высокую точность и лучшее соответствие данным.

#### D. Исследование абляции

Мы проанализировали компоненты DPINN-PF, чтобы количественно оценить их вклад:

- **Физические потери ( $\lambda_1$ ):** их удаление увеличило MAPE на 3,8% и уменьшило количество ПК до 89,2%.
- **Преобразователь повторной выборки:** Замена его на стратифицированную повторную выборку увеличила время вывода на 22% из-за обеднения частиц.
- **Метаобучение:** исправленные  $\lambda_1, \lambda_2$  приводили к увеличению ошибок в переходных режимах на 15%.

### V. ОБСУЖДЕНИЕ И БУДУЩАЯ РАБОТА

#### A. Ограничения дифференцируемого фильтра твердых частиц с усилением PINN

DPINN-PF имеет ограничения: требуются известные граничные условия PDE; неопределённость свойств флюида снижает обобщаемость; трансформерный ресэмплинг увеличивает вычислительные затраты при высокой размерности. Кроме того, метод требует синхронизированных датчиков.

#### B. Возможные сценарии применения DPINN-PF

Помимо MPFM, DPINN-PF применим для задач с физическими ограничениями и адаптацией: локализация утечек, отслеживание фаз  $\text{CO}_2$  и дрейфа характеристик. Требуются дальнейшие исследования, особенно для критичных систем.

#### C. Этические соображения при использовании DPINN-PF

ИИ-метринг несёт риски: ошибки без оценки неопределённости и низкая интерпретируемость усложняют аудит. Рекомендуется: (1) указывать неопределённость, (2) сверять с физическими моделями, (3) сохранять человеческий контроль.

### VI. ЗАКЛЮЧЕНИЕ

DPINN-PF улучшает MPFM, объединяя физически-информированное обучение и адаптивную нелинейную фильтрацию, что снижает вырожденность частиц, уменьшает ручную настройку и повышает точность в реальном времени.

Метод снижает зависимость от эмпирических моделей, повышает устойчивость в переходных режимах и обеспечивает физическую согласованность. Модульная архитектура позволяет расширение (новые ограничения и датчики), с перспективой поддержки асинхронных измерений и федеративного обучения.

### СПИСОК ЛИТЕРАТУРЫ

- [1] G. Falcone, G. Hewitt, and C. Alimonti, *Multiphase Flow Metering: Principles and Applications*. New York, NY, USA: Springer, 2009.
- [2] R. Rashid, M. Mustafa, I. Ismail, and N. Mokmin, "Optimising offshore multiphase flowmeter technology to improve wet gas field efficiency," *Scientific Reports*, vol. xx, pp. 1–12, 2025.
- [3] I. Benlizidia and M. Saeed, "Lessons learned and best practices from multiphase flowmeters implementations," in *Proc. SPE Annual Technical Conference and Exhibition*, 2023, pp. 1–10.
- [4] C. Kwok, D. Fox, and M. Meila, "Real-time particle filters," in *Advances in Neural Information Processing Systems (NeurIPS)*, 2002, pp. 1–8.
- [5] H. Wen, "Differentiable particle filters for time series analysis," 2025. [Online]. Available: [openresearch.surrey.ac.uk](https://openresearch.surrey.ac.uk)
- [6] S. Cai, Z. Mao, Z. Wang, M. Yin, and G. E. Karniadakis, "Physics-informed neural networks (PINNs) for fluid mechanics: A review," *Acta Mechanica Sinica*, vol. 37, no. x, pp. 1–24, 2021.
- [7] H. Jin and W. Liu, "Advancing multiphase flow measurement: Machine learning vs. traditional MPFM in flow loop testing," in *Proc. SPE Annual Technical Conference and Exhibition*, 2025, pp. 1–10.
- [8] A. Skopich *et al.*, "Operational experience with multiphase flow meters," in *Proc. SPE Caspian Technical Conference and Exhibition*, 2019, pp. 1–12.
- [9] D. Chisholm, "A theoretical basis for the Lockhart–Martinelli correlation for two-phase flow," *Int. J. Heat Mass Transfer*, vol. 10, no. 12, pp. 1767–1778, 1967.
- [10] L. Frau, G. Susto, T. Barbariol, and E. Feltresi, "Uncertainty estimation for machine learning models in multiphase flow applications," *Informatics*, vol. 8, no. x, pp. 1–15, 2021.
- [11] E. Ghorbani, Q. Dollon, and F. Gosselin, "Physics-aware tuning of the unscented Kalman filter: A statistical framework for nonlinear dynamical systems," *Nonlinear Dynamics*, vol. xx, pp. 1–20, 2025.
- [12] H. Iqbal, "Neural accelerated marginalized particle filtering for distributed parameter systems," 2024. [Online]. Available: [repositories.lib.utexas.edu](https://repositories.lib.utexas.edu)
- [13] A. Ali, G. Abdul-Majeed, and A. Al-Sarkhi, "Review of multiphase flow models in petroleum engineering," pp. 1–20.