Сети глубокого обучения в задаче модельного управления технологическим процессом

И. С. Лазухин*, М. И. Петровский†, И. В. Машечкин§

Традиционные системы управления технологическими процессами требуют сложной экспертной настройки и часто не успевают за дрейфом характеристик оборудования. Настоящая работа направлена на разработку алгоритмов предиктивного управления, функционирующих исключительно на основе накопленных исторических данных, объединяющих сквозную дифференцируемость нейросетевой модели процесса с классическими методами математического программирования. Работоспособность и переносимость разработанных методов оценены на данных симулятора Теннесси Истмана и реального нефтеперерабатывающего комплекса. Результаты демонстрируют эффективное управление процессом и удержание технологических параметров в заданных ограничениях.

Ключевые слова: модели со структурированным пространством состояний, обучение с подкреплением, цифровой двойник.

1. Задача предиктивного управления

В основе предиктивного управления (англ. Model Predictive Control, MPC) лежит принцип скользящего горизонта: динамическая модель объекта прогнозирует траектории контролируемых переменных на заданный горизонт планирования, а оптимизатор находит последовательность управляющих

* *Лазухин Иван Сергеевич* — м.н.с. каф. интеллектуальных информационных технологий ф-та ВМК МГУ, e-mail: ivanlazuhin@mail.ru.

Lazuhin Ivan Sergeevich — Research Assistant at Lomonosov Moscow State University, Faculty of Computational Mathematics and Cybernetics, Chair of Intelligent Information Technologies Department.

† *Петровский Михаил Игоревич* — к.ф-м.н., доцент каф. интеллектуальных информационных технологий ф-та ВМК МГУ, e-mail: michael@cs.msu.ru.

Petrovskiy Mikhail Igorevich — Ph.D., Associate Professor at Lomonosov Moscow State University, Faculty of Computational Mathematics and Cybernetics, Chair of Intelligent Information Technologies Department.

§ *Машечкин Игорь Валерьевич* — д.ф-м.н., профессор, заведующий каф. интеллектуальных информационных технологий ф-та ВМК МГУ, e-mail: mash@cs.msu.ru.

Mashechkin Igor Valeryevich — Ph.D., Professor at Lomonosov Moscow State University, Faculty of Computational Mathematics and Cybernetics, Head of Intelligent Information Technologies Department.

Опубликовано на условиях лицензии CC-BY 4.0
Published under CC-BY 4.0

воздействий, минимизирующую заданный функционал качества при соблюдении технологических ограничений. На каждом шаге управления из полученной управляющей последовательности отбирается только первый шаг. Классическая парадигма MPC, опирающаяся на знания предметной области, в последние годы переживает сдвиг в сторону предиктивного управления на основе данных [1].

Главной целью данного исследования является разработка алгоритма управления сложными производственными процессами исключительно на основе накопленных исторических данных. Ключевым требованием к предложенному подходу выступает его инвариантность к явным физико-химическим моделям оборудования, что должно обеспечить переносимость алгоритма между различными производственными установками без необходимости их индивидуальной экспертной настройки.

2. Предложенные подходы

Существующие исследования в области либо ограничены системами малой размерности [2], либо жестко привязаны к физико-химическим уравнениям, описывающим конкретный объект [3].

Технологические объекты рассматриваются в виде временных рядов, дискретно дифференцированных для устранения трендов. Исследование опирается на два источника данных: стандартный бенчмарк-симулятор Теннесси Истмана [4] (41 контролируемый датчик – CV и 12 управляющих воздействий – MV) и реальный нефтеперерабатывающий комплекс (35 CV, 7 MV). Для эффективного моделирования многомерных процессов во времени были выбраны модели пространств состояний S4 [5], обеспечивающие эффективное автоматическое дифференцирование на длительных горизонтах (граф не требует развертки) относительно классических рекуррентных сетей. Предложено три класса моделей управления, использующих оптимизатор второго порядка (метод внутренней точки):

1. Прямая одношаговая модель – строит будущие CV по скользящему окну процесса: $\widehat{CV}_{k+1} = P_f(CV_k, CV_{k-1}, \dots, MV_k, MV_{k-1}, \dots)$.
2. Статическая модель – предсказывает траекторию CV непосредственно по последовательности управления: $\widehat{CV}_k, \widehat{CV}_{k-1}, \cdots = P_s(MV_k, MV_{k-1}, \dots)$.
3. Обратная модель – принцип инверсно-ориентированного управления (вводится сдвиг p): $\widehat{MV}_{k-p}, \widehat{MV}_{k-p-1}, \cdots = P_r(CV_k, CV_{k-1}, \dots)$.

Поскольку задача инверсии в условиях немонотонной динамики и шумов является некорректной по Адамару, целевой функционал инверсной оп-

тимизации дополняется регуляризацией, минимизирующей отклонение генерируемого управления от исторического тренда заданного сдвигом p. В качестве альтернативного метода исследована схема обучения с подкреплением, где веса суррогатных моделей используются для инициализации Критика и Актора, что позволяет безопасно развертывать обучение без риска аварийных остановок в рамках среды реального производства.

3. Результаты

Все разработанные подходы продемонстрировали способность устойчиво управлять симулятором в течение длительных интервалов времени (100 минут) без нарушения технологических ограничений. Прямая одношаговая модель и метод на основе обучения с подкреплением показали наилучшие метрики следования заданной траектории стоимости, однако последний продемонстрировал повышенную дисперсию и худшую стабильность по метрикам среднеквадратичного отклонения стоимости. Статическая модель показывает хорошие результаты на симуляторе, но из-за сильного сглаживания оказывается чувствительной к зашумленным реальным данным нефтепереработки.

Наиболее перспективным и стабильным методом для внедрения на реальном производстве показана обратная модель (инверсно-ориентированное управление). За счет перевода сложных нелинейных ограничений на CV в интервальные ограничения на входы оптимизатора и упрощения задачи моделирования процесса, обратный подход обеспечивает более стабильные траектории и надежность поддержания процесса в заданных технологических ограничениях, что подтверждается исследованием производных состояний процесса Теннесси.

Список литературы

[1] M. M. Morato, M. S. Felix, “Data Science and Model Predictive Control: A survey of recent advances on data-driven MPC algorithms”, *Journal of Process Control*, **144**:3 (2024), 103327. DOI: 10.1016/j.jprocont.2024.103327.

[2] M. Zakwan, V. Gupta, A. Karimi, E. Balta, G. Ferrari-Trecate, “Controller design for structured state-space models via contraction theory”, arXiv: 2604.07069.

[3] L. L. Fonseca, L. Böttcher, B. Mehrad, R. C. Laubenbacher, “Surrogate modeling and control of medical digital twins”, arXiv: 2402.05750.

[4] J. J. Downs, E. F. Vogel, "A plant-wide industrial process control problem", *Computers & chemical engineering*, **17**:3 (1993), 245–255. DOI: 10.1016/0098-1354(93)80018-I.

[5] A. Gu, K. Goel, C. Ré, "Efficiently modeling long sequences with structured state spaces", arXiv: 2111.00396.

Статья поступила 25 октября 2026 г.

Deep learning models for predictive control of technological processes

I. S. Lazuhin, M. I. Petrovskiy, I. V. Mashechkin

Traditional control systems for complex technological processes require extensive expert tuning and often fail to adapt to the drift in real equipment characteristics. This study aims to develop purely data-driven predictive control algorithms, combining the end-to-end differentiability of the surrogate model with classical mathematical programming methods. The performance and transferability of the developed methods have been validated using data from the industrial Tennessee Eastman process simulator and a real oil refinery complex. The results demonstrate effective process control and reliable maintenance of technological parameters within specified operational constraints.

Keywords: structured state-space models, reinforcement learning, digital twin.

References

[1] M. M. Morato, M. S. Felix, "Data Science and Model Predictive Control: A survey of recent advances on data-driven MPC algorithms", *Journal of Process Control*, **144**:3 (2024), 103327. DOI: 10.1016/j.jprocont.2024.103327.

[2] M. Zakwan, V. Gupta, A. Karimi, E. Balta, G. Ferrari-Trecate, "Controller design for structured state-space models via contraction theory", arXiv: 2604.07069.

[3] L. L. Fonseca, L. Böttcher, B. Mehrad, R. C. Laubenbacher, "Surrogate modeling and control of medical digital twins", arXiv: 2402.05750.

[4] J. J. Downs, E. F. Vogel, "A plant-wide industrial process control problem", *Computers & chemical engineering*, **17**:3 (1993), 245–255. DOI: 10.1016/0098-1354(93)80018-I.

[5] A. Gu, K. Goel, C. Ré, "Efficiently modeling long sequences with structured state spaces", arXiv: 2111.00396.

Received on October 25, 2026