automation

MDPI

Article

Digital Twin-Based MPC for Industrial MIMO Automation: Intelligent Algorithms

Batyrbek Suleimenov , Olga Shiryayeva*, Dmitriy Gorbunov

Institute of Automation and Information Technologies, Satbayev University, Almaty 050013, Kazakhstan; b.suleimenov@satbayev.university (B.S.)
* Correspondence: o.shiryayeva@satbayev.university

Abstract: В статье предложен предиктивный алгоритм управления для MIMO промышленных процессов, основанный на интеграции цифрового двойника (DT), модели предиктивного управления (MPC), генетического алгоритма (GA) и нейросетевой коррекции (NN). Разработанная архитектура реализует двухканальное управления по предложенной схеме: сбор/очистка данных, линеаризация и обучение NN, оптимизация траектории управления на скользящем горизонте, замыкание обратной связи и адаптация по фактической ошибке (ISD–ML–OP–FPA). Такой инновационный двухканальный закон управления использует линейную модель в пространстве состояний как базовый предиктор и «малую» NN-надстройку для компенсации немоделируемых нелинейностей, при этом GA ищет оптимальную последовательность управляющих воздействий с учётом технологических ограничений и мягкой регуляризации на вклад нейросети. Методология апробирована на реальном процессе очистки ортофосфорной кислоты. Предложенный алгоритм обеспечил повышение степени очистки до 95,1%, снижение интегральной ошибки слежения на 11,4% и уменьшение амплитуды управляющих сигналов на 10–15% по сравнению с базовым MPC. Выбранные режимы подачи реагентов и разрежения позволили достичь устойчивой работы при флуктуациях сырья. Результаты подтверждают эффективность гибридного управления на основе цифрового двойника в задачах, где важны точность, адаптивность и соблюдение ограничений. Подход масштабируем и может быть применён в других непрерывных производственных системах в рамках инициатив Industry 4.0.

Keywords:–digital twin, MIMO automation systems, MPC, hybrid intelligent control, intelligent optimization, phosphoric acid purification.

Academic Editor: Firstname Lastname

Received: date
Revised: date
Accepted: date
Published: date

Citation: To be added by editorial staff during production.

Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

1. Introduction

Современные промышленные процессы отличаются высокой сложностью, особенно в случае многомерных объектов управления (MIMO-систем). Такие системы характеризуются выраженной нелинейностью, задержками и взаимозависимостью переменных, что делает традиционные методы регулирования (например, ПИД-регуляторы или классический MPC) недостаточно эффективными. В условиях высокой динамики и неопределённости они не способны обеспечить требуемое качество управления и энергетическую эффективность [1,2].

В последние годы активно развивается концепция цифровых двойников (DT), представляющих собой виртуальные копии физических объектов. Цифровой

двойник позволяет описывать и прогнозировать поведение системы в реальном времени, что создаёт основу для оптимизации производственных процессов, повышения надёжности и снижения эксплуатационных затрат. В контексте Industry 4.0 цифровые двойники рассматриваются как ключевая технология для реализации интеллектуальных систем управления [3-6]. Исследования показывают, что DT-технологии способны повысить эффективность промышленного мониторинга и диагностики, однако на практике остаются нерешёнными проблемы синхронизации потоков данных, консистентности и масштабируемости [7-9]. Дополнительные аспекты инфраструктуры связи (5G), IoT-сенсорики и организации Smart Manufacturing рассмотрены в [10-13].

Тем не менее, применение цифровых двойников для управления MIMO-системами сталкивается с рядом проблем [14]:

(1) высокая вычислительная сложность, необходимая для моделирования в реальном времени;

(2) трудности масштабирования решений для промышленных объектов;

(3) ограниченные возможности классических методов MPC по адаптации к нелинейностям и возмущениям [15,16].

Для преодоления этих ограничений активно исследуются подходы, сочетающие цифровой двойник с методами искусственного интеллекта и глобальной оптимизации. Такой подход позволяет не только учитывать физическую модель объекта, но и компенсировать её несовершенства с помощью нейросетевых коррекций и эволюционных алгоритмов поиска. Недавние работы демонстрируют эффективность гибридных схем «модель + машинное обучение» для задач управления в химико-технологических процессах [5,17], использование глубоких нейронных сетей в MPC для повышения адаптивности [15,17,18], а также интеграцию методов эволюционной оптимизации и гибридных метаэвристик для поиска оптимальных управляющих воздействий [19,20]. Кроме того, отмечается растущий потенциал цифровых двойников для задач энергосбережения и устойчивого развития [7,9].

Целью данной работы является разработка и апробация адаптивного предиктивного алгоритма управления, основанного на интеграции цифрового двойника, метода предиктивного управления (MPC), генетического алгоритма (GA) и нейронной сети (NN).

Основные научные результаты и вклад статьи заключаются в следующем:

(1) предложена универсальная архитектура цифрового двойника, интегрированная с MPC и модулями искусственного интеллекта для управления MIMO-системами;

(2) реализована гибридная схема оптимизации, сочетающая глобальный поиск GA и нелинейную аппроксимацию NN;

(3) проведена экспериментальная валидация на примере процесса очистки ортофосфорной кислоты, подтвердившая повышение качества регулирования и снижение энергозатрат;

(4) показана масштабируемость предложенного подхода для задач интеллектуального производства в условиях неопределённости.

На рисунке 1 представлена общая схема предлагаемой архитектуры цифрового двойника для решения задач управления MIMO-системами с использованием MPC и интеллектуальных алгоритмов.

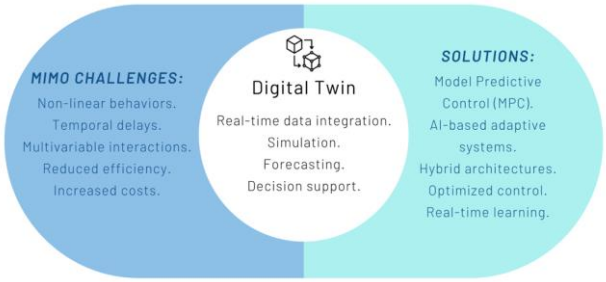


Figure 1. Framework for Addressing MIMO Challenges Using Digital Twin and MPC Solutions.

Статья организована следующим образом: в разделе 2 представлен обзор существующих подходов к управлению MIMO-системами и применению цифровых двойников; в разделе 3 описывается предлагаемая архитектура и алгоритм гибридного предиктивного управления; раздел 4 содержит результаты моделирования и экспериментальной проверки; в заключении (раздел 5) обсуждаются перспективы дальнейших исследований.

2. Literature Review

Разработка интеллектуальных стратегий управления многомерными системами (MIMO) в условиях неопределённости в последние годы привлекает всё больше внимания, особенно в контексте концепции *Индустрия 4.0*. В этой парадигме технологии DT зарекомендовали себя как перспективный инструмент для мониторинга в реальном времени, диагностики и поддержки принятия решений в сложных промышленных процессах [3,4].

Ряд исследований посвящён применению цифровых двойников для повышения наблюдаемости процессов, реализации прогнозной диагностики и повышения эффективности управления. Так, Hu и др. [3] продемонстрировали применение DT для диагностики отказов электрических машин, подчеркнув потенциал гибридного физико-виртуального моделирования в реальном времени. Leng и др. [4] в своём обзоре подробно рассмотрели архитектуры интеллектуального производства на основе цифровых двойников, акцентируя внимание на их роли в повышении эффективности использования оборудования и реализации прогнозного обслуживания. Однако при практической реализации сохраняются трудности, связанные с согласованностью данных, интеграцией в реальные производственные системы и адаптацией к динамическим условиям [7,8].

Параллельно активно развиваются методы MPC, которые зарекомендовали себя как эффективный инструмент для управления многомерными объектами с учётом ограничений и прогнозирования будущего поведения [1,15]. В том числе для анализа надёжности оборудования по временным рядам [21]. Однако классический MPC предъявляет жёсткие требования к точности математических моделей, что ограничивает его применение в нелинейных, изменяющихся или возмущаемых системах. Для нелинейных систем с запаздыванием см. tube-based MPC [22]. В связи с этим всё большую популярность приобретают подходы, интегрирующие элементы машинного обучения и искусственного интеллекта (ИИ**)** в структуру MPC [17,12,20]. Например, Santander и др. [17], а также Chen и др. [18] предложили архитектуры предиктивного управления с использованием глубинных нейронных сетей, демонстрирующие повышение точности прогнозирования и адаптивности в реальных производственных условиях.

Типовые приложения MPC включают энергоменеджмент и микроклимат в зданиях [23-26], приводы и электромеханические системы [27], а также энергоменеджмент гибридных и электрических транспортных средств [28,29]. Связанные многокритериальные применения MPC в смежных отраслях подробно рассмотрены в работах [25,26,30,31].

Одновременно развиваются гибридные схемы оптимизации, объединяющие физическую модель объекта с данными, полученными из наблюдений. El Hakim и др. [20] предложили ИИ-усиленное MPC-управление для оптимизации нелинейных процессов в производстве сжиженного газа, а Herrera и др. [32] разработали гибридный регулятор для управления объектами с большими запаздываниями в химико-технологических системах. Несмотря на перспективность таких решений, они по-прежнему сталкиваются с проблемами адаптации, настройки и вычислительной сложности при работе в реальном времени.

Также следует отметить усилия исследователей по использованию цифровых двойников в целях энергосбережения и устойчивого развития. Teng и др. [7] показали, что DT-инфраструктуры могут эффективно использоваться для оптимизации энергопотребления в промышленности за счёт глубокой интеграции потоков данных. Однако на практике реализация таких решений осложняется необходимостью точной калибровки сенсоров, высокой нагрузкой на вычислительную среду и ограничениями по скорости обработки данных.

Для наглядности в таблице 1 представлено краткое сравнение ключевых исследований, с указанием их основных достижений и оставшихся ограничений.

Table 1. Обзор работ по цифровым двойникам, MPC и ИИ для управления MIMO-системами.

Study	Research Focus and Objectives	Challenges, Limitations, and Drawbacks
Hu et al. (2025) [3]	Digital Twin-based fault diagnosis of electric machines	Difficulties in real-time synchronization and handling multivariable interactions
Ren et al. (2022) [8]	Ontology-based data governance for DT lifecycle management	High data evolution complexity; need for robust semantic architectures
Leng et al. (2021) [4]	Review of DT-based smart manufacturing systems in Industry 4.0	Issues of data consistency, integration, and industrial scalability
Santander et al. (2023) [17]	Deep Learning integrated into MPC frameworks	Scalability for large-scale systems; high computational demand
El Hakim et al. (2025) [20]	AI-enhanced MPC for nonlinear LPG processes	Limited generalizability; requires validation on broader chemical systems
Herrera et al. (2023) [32]	Hybrid controller for long time delays in chemical processes	Complexity of tuning; sensitivity to parameter uncertainty
Teng et al. (2021) [7]	DT infrastructures for industrial energy efficiency	Sensor calibration issues; high demand for real-time processing
This work	Hybrid DT + MPC + GA + NN framework validated	Addresses scalability and adaptability; improves energy efficiency

Таким образом, проанализированная литература демонстрирует устойчивую тенденцию к объединению цифровых двойников, предиктивного управления и алгоритмов искусственного интеллекта. Несмотря на значительный прогресс, многие существующие решения пока не удовлетворяют требованиям к адаптивности и масштабируемости в условиях динамически изменяющихся промышлен-

ных процессов. Настоящая работа направлена на устранение этих ограничений путём разработки гибридной архитектуры управления, сочетающей цифровой двойник, предиктивное управление, генетический алгоритм и нейронную сеть (Рисунок 2), на примере задачи управления процессом очистки ортофосфорной кислоты — типичного химико-технологического объекта с выраженной нелинейностью и множественными входами/выходами.

3. Materials and Methods. Proposed efficient control algorithm

Современные задачи управления MIMO-системами требуют интеграции адаптивных и интеллектуальных подходов, способных учитывать как физическую модель объекта, так и нелинейные, частично наблюдаемые или неопределённые динамические характеристики. В данной работе предлагается предиктивный алгоритм управления, сочетающий линейную модель в пространстве состояний, нейросетевую коррекцию и генетическую оптимизацию управляющих воздействий. Алгоритм реализуется в среде цифрового двойника, что обеспечивает безопасное тестирование и адаптацию стратегий управления в реальном времени [11,16].

Разработка алгоритма включает четыре основных этапа, формирующих полную замкнутую систему управления:

- Input System Data, ISD — формирование и предварительная обработка входных данных: сбор измерений, нормализация, фильтрация и подготовка к моделированию;
- Modeling and Learning, ML — построение математической модели и обучение нейронной сети на подготовленных данных с последующей интеграцией в цифровой двойник для повышения точности предсказаний;
- Optimization Process, OP — прогнозирование динамики системы, расчёт оптимальной траектории управляющих воздействий с учётом ограничений; разложение управления на основную и корректирующую составляющие;
- Feedback and Performance Adjustment, FPA — применение управляющих сигналов к объекту, обновление состояния цифрового двойника, сдвиг предсказательного горизонта и коррекция параметров на основе фактической ошибки.

Такая поэтапная архитектура позволяет реализовать алгоритм управления, устойчивый к неопределённостям и изменяющимся условиям среды. Использование цифрового двойника предоставляет возможность безопасного тестирования различных сценариев и предварительной оптимизации до внедрения решений в реальную производственную среду.

3.1. Этап ввода и предварительной обработки данных (ISD)

На первом этапе гибридного предиктивного управления осуществляется сбор и формирование входной информации, необходимой для построения прогностической модели и реализации цикла оптимизации [11]. Исходной информацией служат текущие операционные измерения MIMO-системы, получаемые в реальном времени с производственного объекта [10]. Ключевые переменные на этом этапе включают: $y(k)$ is вектор измеряемых выходных переменных, отражающих динамическое поведение управляемого объекта; $u(k)$ is вектор управляющих воздействий, подаваемых на систему; $r(k)$ is вектор заданных значений выходов, определяющих желаемую траекторию регулирован; Ω is множество ограничений на переменные $y(k)$ и $u(k)$, определяющее допустимые рабочие области системы.

Перед подачей данных в блок предиктивного управления (MPC) выполняется обязательная предварительная обработка, включающая:

- Масштабирование (нормализация) всех переменных в унифицированный числовой диапазон (например, [0,1]), что необходимо для обеспечения корректной работы нейросетевых компонентов и устойчивости численных процедур оптимизации;
- Фильтрация шумов и выбросов в измеренных данных, позволяющая повысить точность прогноза и устойчивость управляющих воздействий [7,9];
- Валидация и проверка полноты данных, включая контроль на наличие пропусков, выходов за допустимые границы и согласованность между каналами измерений.

В результате формируется очищенный, нормализованный и структурированно согласованный входной вектор, поступающий в блок прогнозирования и оптимизации MPC. Этот этап играет ключевую роль в обеспечении надёжности и устойчивости работы всего гибридного алгоритма управления.

Таким образом, стадия ISD служит связующим звеном между реальной производственной системой и предиктивным регулятором, формируя достоверную основу для принятия управленческих решений в цифровом двойнике.

3.2. Математическая модель и прогноз с нейросетевой коррекцией (ML)

Предиктивное управление (MPC) относится к классу современных стратегий управления, в которых на каждом такте времени решается задача оптимального управления на конечном горизонте. Базовая формулировка MPC начинается с дискретной модели объекта управления в пространстве состояний, которая разрабатывается на основе физических процессов системы управления и обработанных данных [11,16]:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) \\ y(k) &= Cx(k) + Du(k) \end{aligned} \tag{1}$$

where k is discrete time; $x(k)$ is вектор состояния системы; $u(k)$ is управляющий вектор; $y(k)$ is вектор выходных переменных; A, B, C и D are матрицы, полученные в результате идентификации или линеаризации.

Однако реальные технологические процессы, формализованные в цифровом двойнике, часто обладают выраженной **нелинейной** и многомерной динамикой, из-за изменения состава сырья, концентраций, температур и других факторов. В этом случае применяется обобщённая нелинейная модель:

$$\begin{aligned} x(k+1) &= f\big(x(k), u(k), w(k)\big) \\ y(k) &= g(x(k), u(k)) \end{aligned} \tag{2}$$

where $w(k)$ is возмущения среды (например, флуктуации качества сырья или внешние шумы).

Так как классическое MPC требует линейной модели, осуществляется линеаризация системы в окрестности выбранной рабочей точки (x^*, u^*) по Якобианам:

$$A = \frac{\partial f}{\partial x}\Big|_{(x^*,u^*)}, \qquad B = \frac{\partial f}{\partial u}\Big|_{(x^*,u^*)}, \qquad C = \frac{\partial g}{\partial x}\Big|_{(x^*,u^*)}, \qquad D = \frac{\partial g}{\partial u}\Big|_{(x^*,u^*)} \tag{3}$$

После получения линейной дискретной формы при выбранном шаге дискретизации T_s строится модель для применения в MPC [33].

Таким образом, нелинейная модель обеспечивает адекватное описание процесса в рамках цифрового двойника, а ее линеаризованная форма используется на уровне MPC для прогнозирующего управления и оптимизации. На основе модели (1) MPC рассчитывает траектории будущего поведения системы на горизонте предсказания Np [6]:

$$\hat{y}(k+i) = f(x(k), u(k), \dots), \quad i = 1, \dots, N_p. \tag{4}$$

Для повышения точности предсказаний в модель встраивается нейронная сеть (NN), которая корректирует динамику, учитывая нелинейные зависимости и эффекты, не описываемые линейной моделью. Нейронная сеть выполняет роль модели-предсказателя [15,17]:

$$\hat{y}(k+1) = f_{NN}(x(k), u(k); \theta), \tag{5}$$

где θ is параметры обученной сети.

Эта аппроксимация используется внутри оптимизационной процедуры для получения более точного прогноза динамики объекта. Горизонты прогнозирования Np и управления Nc задают интервал, на котором рассчитываются прогноз $\hat{y}(k+i)$ и оптимизируется последовательность $u(k+i)$ (рисунок 2).

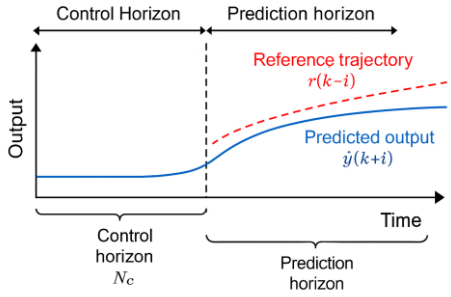


Figure 2. Schematic illustration of Model Predictive Control (MPC) operation

На графике показано сравнение предсказанного выхода $y(k+i)$ (синяя линия) с эталонной траекторией $r(k+i)$ (красная пунктирная линия). Вертикальными линиями обозначены горизонты: Nc is горизонт управления (длина оптимизируемой последовательности управляющих воздействий); Np is горизонт прогнозирования (длина интервала, на котором минимизируется функционал).

Ниже приведён пошаговый алгоритм, обобщающий процедуру подготовки данных и построения модели для реализации гибридного MPC в рамках цифрового двойника.

Algorithm 1 Data Preparation and Model Linearization Procedure for MPC with Digital Twin

Input: states $x(t)$, inputs $u(t)$, outputs $y(t)$, sampling period T_s, historical dataset $\mathcal{D}_{raw}$

Output: cleaned and normalized dataset $\mathcal{D}_{norm}$, linearized discrete-time model (A, B, C, D), digital twin dataset for training NN and predictive control

Begin:

Step 1: Tag definition: States, control inputs, measurable outputs.

Step 2: Range acquisition: Determine minimum/maximum values, define safety and operability limits, Ω.

Step 3: Normalization: Scale all variables to [0,1]: $x^{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$

Step 4: Signal cleaning and validation: Filter high-frequency noise, interpolate missing data, validate against physical constraints.

Step 5: Dataset segmentation for DT/NN Training:

Create subsets for training, validation, and testing (e.g., 70/15/15 split).

Include disturbance-rich scenarios (e.g., feed quality changes, flow surges).

Step 6: Operating point selection: Choose nominal process condition (x^*, u^*), based

on optimal or steady-state operation.

Step 7: Linearization: Compute Jacobians at (x^*, u^*) to derive linearized state-space model (3).

Step 8: Controllability and observability check:

If necessary, design a state observer: Kalman Filter (KF) for Gaussian noise; Extended KF (EKF) for nonlinearities; Unscented KF (UKF) for higher-order accuracy.

End

Далее, на основе полученной модели и предобработанных данных формируется задача оптимизации, включающая расчёт управляющей последовательности с учётом ограничений. Полная формализация задачи, а также структура гибридного регулятора представлены в следующем разделе.

3.3. Optimization Process (OP)

На данном этапе алгоритма управления выполняется оптимизация управляющих воздействий. Каноническая постановка задачи MPC заключается в минимизации целевой функции на горизонте прогноза N_p на каждом шаге времени k:

$$\min_U J(U) = \sum_{i=1}^{N_p} \|y(k+i) - r(k+i)\|_Q^2 + \sum_{i=0}^{N_c-1} \|\Delta u(k+i)\|_R^2; \quad \Delta u(k+i) = u(k+i) - u(k+i-1). \tag{6}$$

Оптимизация проводится при условии выполнения модели в пространстве состояний (1) и ограничений на входные воздействия и их приращения:

$$u_{min} \le u(k+i) \le u_{max}, \quad \Delta u_{min} \le \Delta u(k+i) \le \Delta u_{max}. \tag{7}$$

Здесь $U = \{u(k), \dots, u(k+N_c-1)\}$ is последовательность будущих управляющих воздействий на горизонте управления Nc; $\Delta u(k+i)$ is приращение управления; $y(k+i)$ are прогнозируемые выходы системы; $r(k+i)$ are заданные сигналы; Q, R are весовые матрицы, задающие приоритеты по точности слежения и сглаженности управления.

Каноническая постановка задачи MPC в данной работе расширяется за счёт интеграции гибридных модулей. Прогноз уточняется нейросетевой моделью, а поиск оптимальной последовательности U с учётом (7) выполняется генетическим алгоритмом. Применяются две разные нейросети со схожей архитектурой, но разными задачами:

NNy — модельная нейросеть для аппроксимации модельной ошибки и уточнения прогноза выходов (residual modeling).

NNu — исполнительная нейросеть для генерирования добавочного управляющего воздействия u_{NN} (ancillary/policy control).

Тем самым разделяются функции «моделирования» и «управления», что устраняет двойной учёт одной и той же ошибки. Дополнительно в функционал вводятся штрафные слагаемые на нейросетевую коррекцию и её приращения, что позволяет обеспечить робастность и предсказуемость поведения системы в условиях неопределённости [19,27].

Итоговый закон управления имеет гибридный вид:

$$u(k) = u_{GA}(k) + u_{NN}(k), \qquad u_{NN}(k) = f_{NN}(\hat{x}(k), u(k-1); \theta), \tag{8}$$

где $u_{GA}(k)$ is результат глобальной оптимизации с использованием генетического алгоритма, минимизирующего критерий $J(U)$; $u_{NN}(k)$ is корректирующая добавка нейросетевой модели, компенсирующая неучтённую динамику объекта; f_{NN} — политика сети NNu, зависящая от оценки состояния $\hat{x}$ и доступного контекста; θ — параметры обученной нейросети; .

Управляющее воздействие, сгенерированное нейросетью u_{NN}, считается фиксированным на горизонте управления и не подлежит оптимизации. Это позволяет исключить двойной учёт ошибки и обеспечить структурную декомпозицию задачи управления. Предлагается ограничить влияние нейросетевой корректировки введением мягкой регуляризации в целевую функцию MPC. Расширенный функционал в этом случае будет иметь вид [15,17]:

$$J_{tot}(U) = J(U) + \beta \sum_{i=0}^{N_c-1} \|u_{NN}(k+i)\|^2 + \rho \sum_{i=0}^{N_c-1} \|\Delta u_{NN}(k+i)\|^2, \quad (9)$$

$J(U)$ – базовый критерий MPC; $\Delta u_{NN}(k+i) = u_{NN}(k+i) - u_{NN}(k+i-1)$ is приращение нейросетевого управления.

Коэффициенты $\beta, \rho \geq 0$ задают веса штрафов. Первое слагаемое ограничивает амплитуду нейросетевой составляющей, второе — скорость её изменения. Такая регуляризация предотвращает «агрессивные» коррекции и способствует соблюдению ограничений на управляющие входы.

На каждом такте управления используется принцип скользящего горизонта: оптимизируется вся последовательность U, однако в реальном контуре применяется только первый элемент $u(k)$. Далее система переходит в состояние $x(k+1)$, и оптимизация повторяется с обновлёнными измерениями. Для начального шага используется приращение $\Delta u(k) = u(k) - u(k-1)$, где $u(k-1)$ is последний реально поданный сигнал на объект.

Для минимизации критерия (2) на горизонте управления используется генетический алгоритм (GA). Он формирует множество кандидатных последовательностей: $U = \{u(k), u(k+1), \ldots, u(k+Nc-1)\}$, оценивает их качество по расширенному функционалу J_{tot}, где прогнозы $\hat{y}$ рассчитываются моделью в пространстве состояний и нейросетевым предсказателем [19,27].

Нейронная сеть выполняет функцию предсказателя и корректирующего канала: она уточняет прогнозы выходных переменных $\hat{y}$ и формирует добавку $u_{NN}(k)$, компенсирующую несмоделированную нелинейную динамику. Обучение проводится офлайн на основе исторических данных, а в процессе эксплуатации допускается мягкое дообучение малыми шагами. Вклад нейросетевого канала ограничивается штрафными слагаемыми в функционале J_{tot}, что повышает робастность и предотвращает нежелательные резкие коррекции [15,17].

Научная новизна. Предлагаемый гибридный закон управления реализуется в форме **двухканального сигнала** (3), где первый канал генерируется предиктивным регулятором с генетической оптимизацией, а второй представляет собой малую нейросетевую коррекцию. В отличие от традиционных подходов [22], где штрафы накладываются на общий управляющий сигнал или параметры модели, в данной работе введена явная регуляризация именно для нейросетевой добавки и её приращений. Такая постановка позволяет контролировать амплитуду и скорость изменения обучаемого канала, сохраняя его эффективность как компенсатора модельной ошибки и обеспечивая при этом соблюдение ограничений и запасы устойчивости.

С точки зрения теории автоматического управления предложенный подход объединяет прогноз линейной модели в пространстве состояний с малой корректирующей надстройкой, которая функционирует как дополнительный канал обратной связи (*ancillary feedback controller*). С позиции оптимального управления итоговая задача остаётся стандартной задачей MPC на скользящем горизонте: GA определяет оптимальную последовательность входов по функционалу слежения и сглаживания, а нейросеть уточняет прогноз траекторий и ограниченно компенсирует нелинейности. Введённые коэффициенты β, ρ гарантируют малость и огра-

ниченность нейросетевого воздействия, что обеспечивает робастность и предсказуемость поведения регулятора при наличии неопределённостей [19,27].

В результате достигается более точное слежение за эталонной траекторией при соблюдении ограничений, повышается технологическая эффективность процесса (в частности, степень очистки), при этом структура регулятора остаётся совместимой с классическими принципами анализа устойчивости замкнутых систем.

3.4. Feedback and Perfomance

Завершающий этап алгоритма предиктивного управления is the **Feedback and Performance Adjustment (FPA) step**. Он обеспечивает замыкание контура управления, реализацию принципа скользящего горизонта и адаптацию системы к текущим условиям. На этом этапе оптимальное управляющее воздействие, рассчитанное на предыдущем шаге, подаётся на объект, после чего измеряются реальные выходы процесса, обновляются состояния модели и формируется новая задача оптимизации. Таким образом, FPA выполняет роль механизма обратной связи, позволяющего корректировать прогнозы и поддерживать устойчивость и эффективность работы регулятора в реальном времени [7,9].

После того как на горизонте оптимизации найдена оптимальная последовательность управляющих воздействий $U^* = \{u^*(k), u^*(k+1), \dots, u^*(k+Nc-1)\}$, в реальном контуре используется только её первый элемент. Таким образом, на объект подаётся сигнал

$$u(k) = u^*_{GA}(k) + u^*_{NN}(k), \tag{10}$$

состоящий из результата глобальной оптимизации с применением генетического алгоритма и малой нейросетевой коррекции. После применения управления измеряется фактический выход системы $y(k)$, и на его основе вычисляется ошибка слежения

$$e(k) = r(k) - y(k). \tag{11}$$

Эта ошибка используется для обновления вектора состояния модели, что может быть реализовано как напрямую через уравнение состояния (1), так и с применением наблюдателя (например, Люнбергера или EKF), если полный вектор состояний недоступен. В последнем случае оценка состояния уточняется с учётом расхождения между модельным прогнозом и фактическим выходом.

Далее происходит сдвиг горизонта оптимизации (принцип **receding horizon**): на следующем шаге времени заново формируется задача минимизации расширенного функционала $J_{tot}(U)$ с учётом обновлённых данных и наложенных ограничений. Такой замкнутый цикл позволяет регулятору непрерывно адаптироваться к изменяющимся условиям, корректировать прогнозы и сохранять требуемые показатели устойчивости и качества управления.

Таким образом, этап FPA завершает методологию гибридного MPC, обеспечивая замыкание обратной связи и непрерывное обновление управляющих воздействий. В результате предложенный алгоритм сохраняет структуру классического предиктивного управления, но дополняется двумя модулями — глобальной оптимизацией с помощью генетического алгоритма и ограниченной нейросетевой коррекцией, что позволяет повысить точность слежения и робастность системы при наличии нелинейностей и неопределённостей.

3.5. Шаги гибридного эффективного алгоритма управления

Для практической реализации предложенного гибридного предиктивного регулятора целесообразно представить его работу в виде пошагового алгоритма.

Такой формат позволяет ясно проследить логику взаимодействия основных этапов и показать, как формируется и корректируется управляющее воздействие в режиме реального времени. Алгоритм 2 включает последовательность действий от сбора данных до применения оптимального сигнала на объект управления и сдвига горизонта прогнозирования.

Algorithm 2. Hybrid MPC with Genetic Algorithm and Neural Network Correction

Input:

Discrete-time state-space model matrices A, B, C, D; prediction horizon Np; control horizon Nc; weights Q, R; regularization coefficients β, ρ; constraints u_{min}, u_{max}, $\Delta u_{min}, \Delta u_{max}$; GA parameters (population size, crossover and mutation rates, elitism factor); trained NN $f_{NN}(x, u; \theta)$; previous input $u(k-1)$.

Output: Applied control input $u(k)$, predicted trajectory $\hat{y}(k+i)$, total cost J_{tot}.

Initialization:

1. Define the plant state-space model (1)
2. Specify the MPC cost, $J(U)$, over horizons N_p, N_c (6); extend to J_{tot} (9).
3. Initialize NN (architecture, weights θ); train offline on historical data.
4. Set GA parameters and define hard constraints for $u, \Delta u$.
5. Initialize observer (KF/EKF/UKF).

Repeat at each time step *k*:

Step 1: Measurement and preprocessing.

Measure output $y(k)$, perform normalization and noise filtering.

Estimate current state $\hat{x}(k)$ (e.g., with Kalman filter).

Step 2: NN correction.

Compute compensating signal: $u_{NN}(k) = f_{NN}(\hat{x}(k), u(k-1); \theta)$.

Step 3: GA initialization.

Generate initial population of candidate control sequences

$$U = \{u(k), \dots, u(k+N_c-1)\}$$

satisfying: $u_{min} \le u(k+i) \le u_{max}$, $\Delta u_{min} \le \Delta u(k+i) \le \Delta u_{max}$.

Step 4: Trajectory prediction for each candidate U:

for $i = 0$ to $N_p - 1$

$$\hat{x}(i+1) = A\hat{x}(i) + B\big(u(k+i) + u_{NN}(k+i)\big)$$
$$\hat{y}(i+1) = C\hat{x}(i) + D\big(u(k+i) + u_{NN}(k+i)\big)$$

Step 5: Compute objective function:

$$\min_U J(U) = \sum_{i=1}^{N_p} \|\hat{y}(k+i) - r(k+i)\|_Q^2 + \sum_{i=0}^{N_c-1} \|\Delta u(k+i)\|_R^2$$

$$\min_U J_{tot}(U) = J(U) + \beta \sum_{i=0}^{N_c-1} \|u_{NN}(k+i)\|^2 + \rho \sum_{i=0}^{N_c-1} \|\Delta u_{NN}(k+i)\|^2$$

Step 6: **GA Evolution:** Apply selection → crossover → mutation → elitism.

Choose best U^* minimizing $J_{tot}(U)$.

Step 7: Apply first control move:

$u(k) = u_{GA}^*(k) + u_{NN}(k)$,

Send $u(k)$ to plant, shift horizon: $k \leftarrow k+1$.

Optional: Update NN (small-step adaptation if error exceeds threshold).

End Repeat

3.8. Digital Twin Implementation

Алгоритм гибридного предиктивного управления интегрируется в цифровой двойник, связанный с PLC через Siemens TIA Portal, как показано на рисунке 3 [11,16].

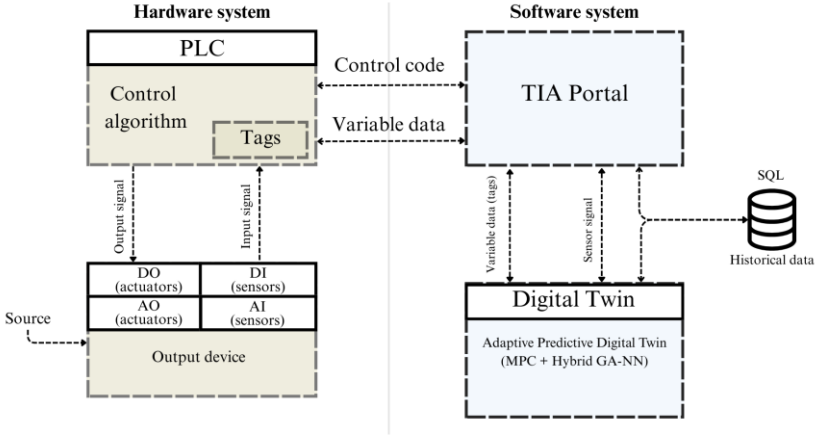


Figure 3. Интеграция аппаратных и программных компонентов для реализации алгоритма управления на основе цифрового двойника.

PLC исполняет управляющий код и обрабатывает сигналы от датчиков (AI, DI), подавая управляющие воздействия на исполнительные устройства (AO, DO). Обмен данными с цифровым двойником осуществляется через тэги, а исторические данные сохраняются в базе SQL и используются для калибровки модели и дообучения нейросети [11,16].

Разработанная методология гибридного предиктивного управления полностью встроена в данную конфигурацию:

- На этапе **Input System Data (ISD)** цифровой двойник получает реальные данные с датчиков через PLC и тэги, выполняет нормализацию и валидацию.
- На этапе **Optimization Process (OP)** цифровой двойник использует предиктивную модель, модуль нейросетевой коррекции и генетический алгоритм для расчёта оптимальных управляющих воздействий с учётом ограничений.
- На этапе **Feedback and Performance Adjustment (FPA)** в физический объект подаётся только первый элемент оптимальной последовательности $u(k)$, после чего цифровой двойник обновляет состояние модели и инициирует новый цикл оптимизации.

Таким образом, цифровой двойник служит **связующим звеном** между методологией и реальной системой, позволяя реализовать замкнутый цикл управления с прогнозом и адаптацией. В отличие от традиционных схем, предложенный подход не ограничивается только оффлайн-моделированием, а обеспечивает **непрерывное взаимодействие виртуальной модели и физического процесса**, что существенно повышает точность и надёжность управления в условиях неопределённости.

4. Results and discussion

Для апробации разработанной методологии, представленной в разделе 3, она была применена к реальному промышленному кейсу — процессу очистки ортофосфорной кислоты марки А (пищевая). Процесс очистки ортофосфорной кислоты представляет собой характерный пример нелинейной MIMO-системы, для

которой свойственны выраженные нелинейности, многопараметрические взаимодействия и наличие возмущений. Строгие требования к качеству конечного продукта, а также необходимость обеспечения устойчивости и энергоэффективности управления делают данный объект показательным примером для демонстрации преимуществ гибридного предиктивного управления с использованием цифрового двойника [7,9].

4.1. Process. Experimental Setup

Пищевая ортофосфорная кислота широко применяется в химической и фармацевтической промышленности. Для её получения применяется метод осаждения примесей термической кислоты в виде сульфидов с помощью сероводорода, образующегося при реакции с раствором сернистого натрия [34].

Процесс протекает в реакционных колоннах (рисунок 4): в верхнюю часть колонны поступает фосфорная кислота (H_3PO_4) с концентрацией 74–78%, а в нижнюю – 4–5% раствор сульфида натрия (Na_2S), подаваемый в соотношении 1:(45–50) относительно кислоты.

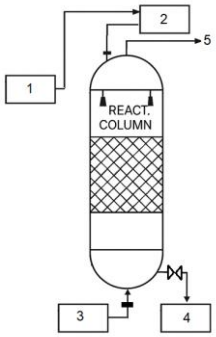


Figure 4. Технологическая схема процесса осаждения сульфидов мышьяка и свинца

1 - бак фосфорной кислоты, 2-напорный бак, 3 - бак для раствора Na_2S. 4 - бак с фосфорной кислотой и активированным углем, 5 – в абсорбер

В результате реакции в нижней части колонны образуется сероводород (H_2S), который взаимодействует с тяжёлыми металлами: мышьяковистой кислотой, As(III), H_3AsO_3; мышьяковой кислотой, As(V), H_3AsO_4; дигидрофосфатом свинца, Pb(II), $Pb(H_2PO_4)_2$. В результате взаимодействия этих компонентов с сероводородом протекают реакции осаждения, в результате которых из раствора выпадают нерастворимые сульфиды: сульфид мышьяка (As_2S_3) и сульфид свинца (PbS). Основные химические реакции [35]:

$$\begin{gathered} Na_2S + 2H_3PO_4 \rightarrow 2NaH_2PO_4 + H_2S\uparrow \\ 2H_3AsO_3 + 3H_2S \rightarrow As_2S_3\downarrow + 6H_2O \\ 2H_3AsO_4 + 5H_2S \rightarrow As_2S_3\downarrow + 8H_2O + 2S\downarrow \\ Pb(H_2PO_4)_2 + H_2S \rightarrow PbS\downarrow + 2H_2PO_4 \end{gathered} \quad (12)$$

Ключевой стадией процесса является осаждение As и Pb, определяющее качество конечного продукта. Для достижения степени очистки фосфорной кислоты от примесей As и Pb выше 95% необходимо поддерживать оптимальные режимы подачи реагентов $F_{H_3PO_4}$, F_{Na_2S}, отвода суспензии F_S, а также разрежение в верхней части колонны, P. Увеличение расхода кислоты и общей производительности снижает время контакта с H_2S, ограничивая полноту осаждения. Это создаёт про-

тиворечие между глубиной очистки и производительностью, что требует применения оптимального управления.

Постановка задачи: Обеспечить глубину очистки более 95%, при соблюдении допустимых режимов подачи H_3PO_4, Na_2S, отвода суспензии и вакуумирования в колонне.

В соответствии с этапом ISD, для рассматриваемой задачи очистки ортофосфорной кислоты определяются основные сигналы и теги цифрового двойника (DT-теги), которые включают:

Состояния $x1, \ldots, x7$ — концентрации ключевых компонентов раствора и объём (или уровень) в нижней части колонны.

Управления $u1, u2, u3, u4$ — расход исходной кислоты, расход раствора Na_2S, расход или слив суспензии, а также воздействие на систему разрежения или вспомогательные управляющие воздействия.

Измеряемые выходы y — показатели качества процесса, используемые в качестве ключевых показателей эффективности (KPI). В частности, для контроля качества очистки в качестве выходов выбираются переменные $x4, x5, x6$, характеризующие концентрации $As(III), As(V)$ и $Pb(II)$, а также $x7$ — текущий объём или уровень раствора.

Переменные состояния, выходы процесса и управляющие воздействия представлены в таблице 1.

Таблица 1 Переменные и параметры модели

обозначение		Описание	units
$C_{H_3PO_4}$	$x_1(t)$	концентрация ортофосфорной кислоты в объёме раствора в нижней части колонны	%
C_{H_2S}	$x_2(t)$	концентрация сероводорода в растворе	kg/h
C_{Na_2S}	$x_3(t)$	концентрация сернистого натрия в объеме раствора	%
$C_{H_3AsO_3}$	$x_4(t)$	концентрация arsenious acid в объеме раствора	%
$C_{H_3AsO_4}$	$x_5(t)$	концентрация arsenic acid в растворе	%
$C_{Pb(H_2PO_4)_2}$	$x_6(t)$	концентрация ионов свинца в растворе	%
V	$x_7(t)$	объём раствора в нижней части колонны	Часть объёма колонны
$F_{H_3PO_4}$	$u_1(t)$	расход исходной фосфорной кислоты H_3PO_4 поступающей из бака 1 в колонну	kg/h
F_{Na_2S}	$u_2(t)$	расход Na_2S, подаваемого в нижнюю часть колонны	t/h
F_S	$u_3(t)$	расход суспензии из нижней части колонны	t/h
P	$u_4(t)$	разряжение в верхней части колонны	Pa
	K_1	константа скорости реакции (1)	
	K_{2-4}	константы осаждения (2-4)	
	K_{5-7}	коэффициенты влияния разряжения (2-4)	

В соответствии с этапом ML для формализации динамики процесса очистки ортофосфорной кислоты предложена математическая модель в виде системы дифференциальных уравнений, основанная на законах материального баланса и кинетике гомогенно-гетерогенных реакций [35,36]:

$$\begin{aligned}\dot{x}_1(t) &= -K_1 x_3(t)\cdot x_1(t) + \frac{x_1(t)}{x_7(t)}u_{1(t)}\\ \dot{x}_2(t) &= -\big(K_2 x_4(t) + K_3 x_5(t) + K_4 x_6(t)\big)\cdot x_2(t) + K_1 x_1(t) x_3(t)\\ \dot{x}_3(t) &= -K_1 x_1(t)\cdot x_3(t) - \frac{x_3(t)}{x_7(t)}u_2(t)\end{aligned} \quad (13)$$

В первых трёх уравнениях описана кинетика образования и распределения сероводорода H_2S, который вступает в реакции осаждения с примесями As и Pb. Далее следуют уравнения для динамики концентраций осаждаемых веществ:

$$\begin{aligned}\dot{x}_4(t) &= -K_2 x_2(t)\cdot x_4(t) + \frac{x_4(t)}{x_7(t)}u_1(t) + K_5 u_4(t)\\ \dot{x}_5(t) &= -K_3 x_2(t)\cdot x_5(t) + \frac{x_5(t)}{x_7(t)}u_1(t) + K_6 u_4 \quad (t)\\ \dot{x}_6(t) &= -K_4 x_2(t)\cdot x_6(t) + \frac{x_6(t)}{x_7(t)}u_1(t) + K_7 u_4(t)\end{aligned} \quad (14)$$

Уравнение для $x_7(t)$ отражает изменение объёма раствора в реакционной колонне за счёт разности между подачей кислоты и отводом суспензии:

$$\dot{x}_7(t) = u_1(t) - u_3(t). \quad (15)$$

Выходами модели, подлежащими контролю и оптимизации, являются:

$$y_1(t) = x_3(t), \qquad y_2(t) = x_4(t), \qquad y_3(t) = x_5(t), \qquad y_4(t) = x_6(t). \quad (16)$$

Коэффициенты кинетики и массопереноса были идентифицированы на основе экспериментальных данных:

$$K_1 = 0.35, \quad K_2 = 0.12, \quad K_3 = 0.18, \quad K_4 = 0.26, \quad K_5 = 0.1, \quad K_6 = 0.1, \quad K_7 = 0.1. \quad (17)$$

Полученная модель адекватно описывает процесс и используется для построения цифрового двойника и разработки гибридного алгоритма MPC [6].

4.2. Результаты применения алгоритма

В данном разделе приведены результаты реализации интеллектуального MPC-регулятора с цифровым двойником, генетическим алгоритмом и двумя нейросетевыми модулями для процесса очистки ортофосфорной кислоты. Процесс очистки H_3PO_4 является MIMO процессом и ограниченным по управляющим воздействиям: вектор управлений включает, например, расход исходной кислоты, подачу раствора Na_2S, расход/слив суспензии и разрежение (вакуум), тогда как измеряемые выходы — концентрации примесей (As(III)/As(V), Pb), газовая фаза H_2S, а также технологические показатели качества. Межканальные перекрёстные связи (сильная чувствительность примесей к нескольким потокам сразу), задержки, интегральные эффекты и нелинейности (реакции осаждения, массообмен, гидродинамика многофазной среды) делают классические одноканальные подходы недостаточными.

На рисунке 5 представлена обобщённая структурная схема реализованной системы алгоритма оптимального управления промышленным процессом очистки ортофосфорной кислоты, в которую входят основные модули управления.

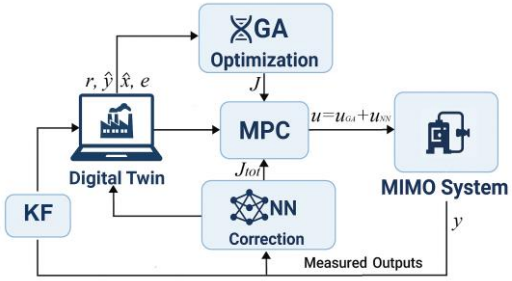


Figure 5. Структурная схема гибридной MPC-системы управления

Система использует комбинацию точных моделей и нейросетевых коррекций для повышения точности прогноза при флуктуациях входных данных и нелинейностях. Применение фильтра Калмана (KF) обеспечивает оценку состояния на основе измеренных выходов, а цифровой двойник — согласование модели с реальными условиями функционирования процесса. Это особенно важно при наличии флуктуаций состава исходного сырья, нелинейностей и задержек, характерных для систем с многофазными потоками и химическими реакциями.

4.2.1. Инициализация алгоритма

Линеаризация выполнена на основе математической модели (уравнения (5)–(11)) и 72-часового набора экспериментальных данных. Рабочая точка выбрана по средним технологическим режимам:

$$u_1^* = 7200\text{kg}\cdot\text{h}^{-1},\ Na_2S\ u_2^* = 730\text{kg}\cdot\text{h}^{-1},\ u_3^* = 7150\text{kg}\cdot\text{h}^{-1},\ u_4^* = 1200Pa,\ x_7^* = 0.15V_{col}. \quad (18)$$

В отклонениях от рабочей точки $\delta\dot{x} = x - x^*,\ \delta u = u - u^*,\ \delta y = y - y^*$ непрерывная линейная модель имеет вид:

$$\delta\dot{x}(t) = A_c\delta x(t) + B_c\delta u(t), \quad \delta y(t) = C\delta x(t) + D\delta u(t), \quad (19)$$

где $x\epsilon\mathbb{R}^7$ – вектор состояний; $u\epsilon\mathbb{R}^4$ is управляющие воздействия; $y\epsilon\mathbb{R}^4$ is выходы системы (концентрации $\text{As(III)}, \text{As(V)}, \text{Pb(II)}, \text{H}_2\text{S}$).

Дискретизация при шаге $T_s = 1\text{h}$ выполнена через матричную экспоненту:

$$A_d = e^{A_cT_s}, \quad B_d = \int_0^{T_s} e^{A_c\tau}B_c d\tau, \quad (20)$$

в результате чего получена дискретная модель

$$\delta x(k+1) = A_d\delta x(k) + B_d\delta u(k), \quad \delta y(k) = C\delta x(k) + D\delta u(k). \quad (21)$$

Численные матрицы A_d, B_d, C, D приведены в Приложении А. Собственные значения матрицы $A_d = \{0.82, 0.76, 0.61, 0.55, 0.43, 0.31, 0.12\}$, лежат внутри единичного круга, что подтверждает устойчивость дискретного предиктора. Полученный набор A_d, B_d, C, D далее используется в модуле MPC [7,9].

4.2.2. MPC Cost Function Specification

Для оптимизации использовалась целевая функция (6) на горизонтах $N_p = 10$ и $N_c = 5$. Такой выбор отражает инерционные свойства процесса осаждения: основные изменения концентраций $\text{As(III)}, \text{As(V)}, \text{Pb(II)}$ происходят в пределах 10–15 часов; N_p охватывает ключевой переходный участок траектории, а укороченный N_c повышает устойчивость и снижает размерность задачи. Соотношение $N_p \approx 2N_c$ соответствует промышленной практике настройки MPC для умеренно-быстрых объектов [33].

Весовые матрицы и параметры регуляризации (расширенная постановка (9)) заданы как

$$Q = diag(10;\ 20;\ 20;\ 15), \quad R = diag(0.5;\ 0.3;\ 0.3;\ 0.2),\ \beta = 0.10,\ \rho = 0.01. \tag{22}$$

Матрица Q подчёркивает приоритет минимизации примесей As и Pb на выходе; матрица R ограничивает резкие изменения Δu (особенно по каналам подачи кислоты u_1 и раствора u_2); коэффициенты β, ρ сглаживают вклад нейросетевой коррекции, повышая робастность и предсказуемость управления.

Выбранные параметры обеспечивают баланс между точностью слежения, вычислительной эффективностью и устойчивостью гибридного регулятора в условиях неопределённостей.

4.2.3. Neural Network Initialization and Training

Для повышения точности предсказаний в контуре MPC используется нейросетевой модуль, компенсирующий нелинейности и неучтённые возмущения. В частности, нейросеть используется для уточнения траекторий выходных переменных $\hat{y}(k+i)$ в пределах горизонта предсказания, а также формирует добавку к управлению $u_{NN}(k)$.

На данном этапе реализован многослойный перцептрон (MLP) с входным вектором $[x_1, \dots, x_7, u_1, \dots, u_4]$. Обученная нейронная сеть содержит два полносвязных скрытых слоя (10 и 6 нейронов, активация ReLU) и выходной слой из четырёх нейронов для прогноза целевых выходных переменных (x_3, x_4, x_5, x_6) (рисунок 6).

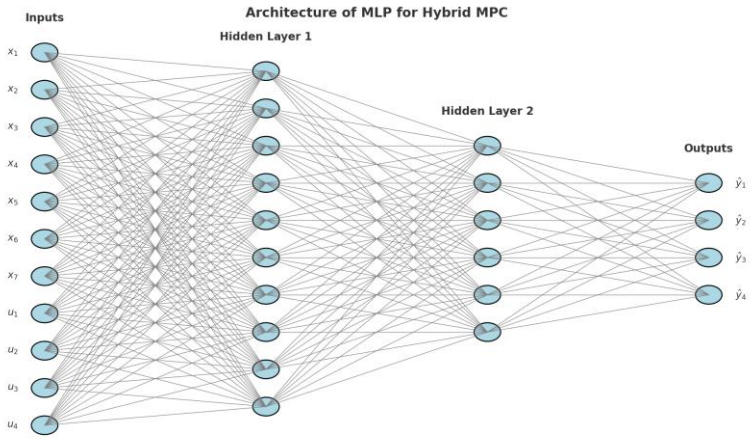


Figure 6. Архитектура нейронной сети (MLP) для гибридного управления

Использованы исторические и экспериментальные данные процесса очистки ортофосфорной кислоты (72 ч). Все признаки нормализованы в [0,1]; выполнены фильтрация выбросов и интерполяция пропусков. Для корректной оценки качества модели весь набор данных был разделён на три части: 70% использовалось для обучения, 15% — для валидации, а оставшиеся 15% — для тестирования. Обучение выполнялось с использованием алгоритма Adam, при этом применялись методы регуляризации (Dropout, L2) для снижения риска переобучения. На рисунке 7 представлены графики изменения RMSE и функции потерь (Loss) для обучающей и валидационной выборок в процессе обучения сети.

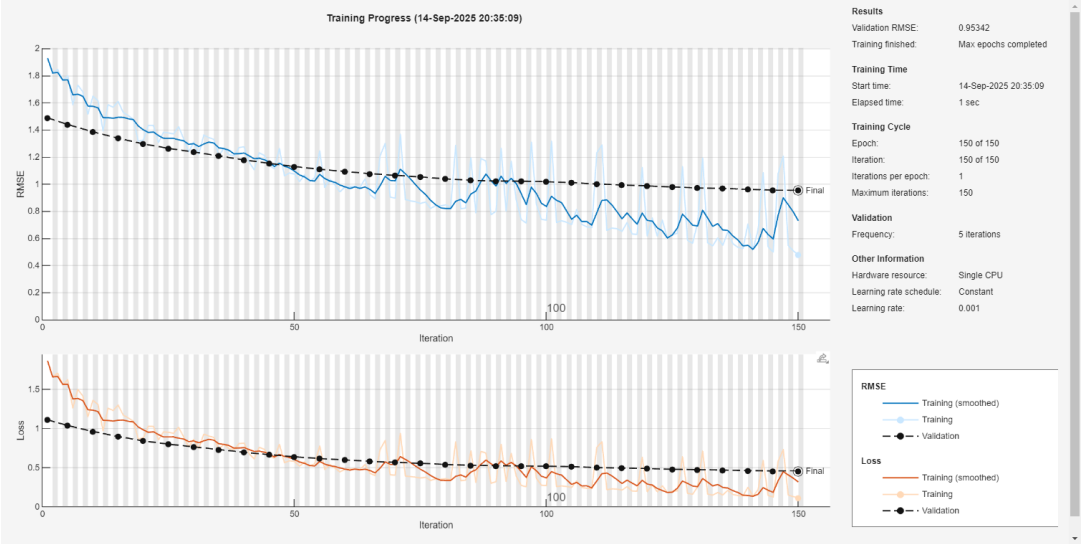


Figure 7. Результаты обучения нейронной сети для прогноза выходов

Анализ кривых обучения нейронной сети (рис. X) показывает устойчивое снижение среднеквадратичной ошибки (RMSE) и функции потерь (MSE) на протяжении всех эпох обучения. На начальном этапе RMSE превышал 1.0, однако уже к пятидесятой итерации ошибка снизилась более чем вдвое, а к завершению обучения достигла значений порядка 0.02–0.05 в нормализованных координатах. Кривая MSE демонстрирует аналогичную динамику: функция потерь сократилась с исходного уровня около 0.5 до менее чем 0.01, что свидетельствует о высокой точности аппроксимации. Отсутствие расхождения между кривыми обучения и валидации подтверждает, что процесс обучения проходил без переобучения и сеть обладает хорошей обобщающей способностью. Таким образом, обученная нейронная сеть адекватно воспроизводит зависимости между входными параметрами процесса и концентрациями примесей, что делает её пригодной для интеграции в контур MPC в качестве корректирующего предсказателя [15,17].

Для иллюстрации предсказательной способности нейросетевой модели, встроенной в состав MPC-контроллера, был построен график изменения выходного параметра $\hat{y}(k+i)$ на горизонте предсказания (рисунок 8). В данной модели процесс очистки фосфорной кислоты описывается совокупностью математических уравнений и нейросетевого корректирующего блока. При этом используются два ключевых параметра: горизонт управления Nc, в течение которого вычисляются управляющие воздействия, и горизонт предсказания Np, на котором осуществляется прогноз качества продукта на выходе.

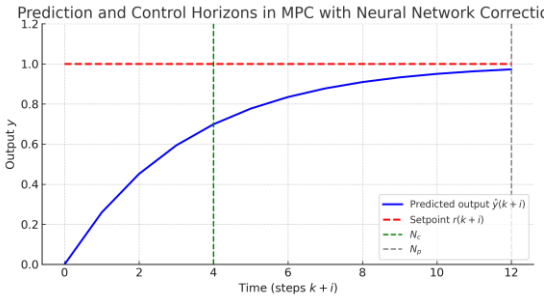


Figure 8. Горизонты прогноза и управления в MPC с нейросетевой коррекцией

На рисунке показана типичная реакция выхода системы под действием управляющего воздействия. Синяя кривая отображает предсказанный выход нейросетевой модели, а красная пунктирная линия — установленное задание (уставку). Зелёная и серая вертикальные линии соответствуют горизонтам управления $Nc = 4$ и предсказания $Np = 12$, соответственно.

Как видно из рисунка, нейросетевая модель позволяет достаточно точно предсказать поведение выходных параметров в будущем, обеспечивая своевременную реакцию MPC-контроллера. Это особенно важно в условиях, когда математическая модель процесса не может в полной мере учесть все нелинейности и стохастические возмущения. Предлагаемый гибридный подход (физическая модель + нейросеть) повышает адаптивность управления и устойчивость к неопределённостям технологического процесса.

4.3. Control Results and Performance

В данном разделе представлены результаты применения предложенного алгоритма управления 2 к задаче очистки ортофосфорной кислоты марки А. Целью управления является минимизации концентраций $As(III), As(V), Pb(II)$ и H_2S при соблюдении ограничений на расход реагентов и вакуум.

Для оптимизации критерия (6) применялся стандартный GA (размер популяции 50, вероятность кроссовера 0.8, мутации 0.05, элитизм 10%, число поколений 25). Управляющие последовательности формировались в пределах ограничений $u_i \epsilon [u_{i,min}, u_{i,max}]$, $\Delta u_i \epsilon [-100, 100]$. Целевая функция включала ошибки слежения, энергозатраты и штрафы за избыточные корректировки нейросетевого канала [19,27].

Дополнительный сигнал $u_{NN}(k)$ формировался с помощью многослойного перцептрона (MLP) с 11 входами $[x_1, \dots, x_7, u_1, \dots, u_4]$, двумя скрытыми слоями (10 и 6 нейронов) и четырьмя выходами. Архитектура идентична сети, использованной в модели прогнозирования, однако выходные нейроны отвечают за компенсационные управляющие воздействия. Обучение проводилось с использованием Adam и регуляризаций Dropout и L2 до достижения $MSE < 0.01$.

Сравнительный анализ показал, что базовый MPC обеспечил степень очистки 91.2%, добавление GA повысило результат до 92.3%, а интеграция NN позволила достичь 95.1%. При этом наблюдалось снижение интегральной ошибки слежения (IAE) на 11.4%, уменьшение колебаний управляющих сигналов на 10–15% и высокая устойчивость к шумам и неопределённостям модели.

На Рисунке 9 представлена сравнительная эффективность трёх стратегий по глубине очистки и устойчивости.

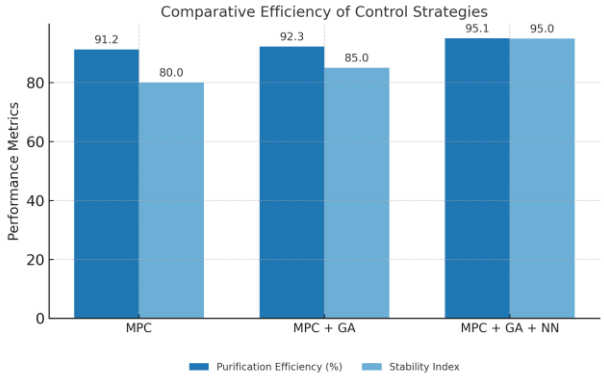


Figure 9. Сравнение стратегий управления по показателям эффективности и устойчивости

На рисунке 10 показана динамика функционала J_{tot} и его составляющих в течение первых 20 часов эксперимента.

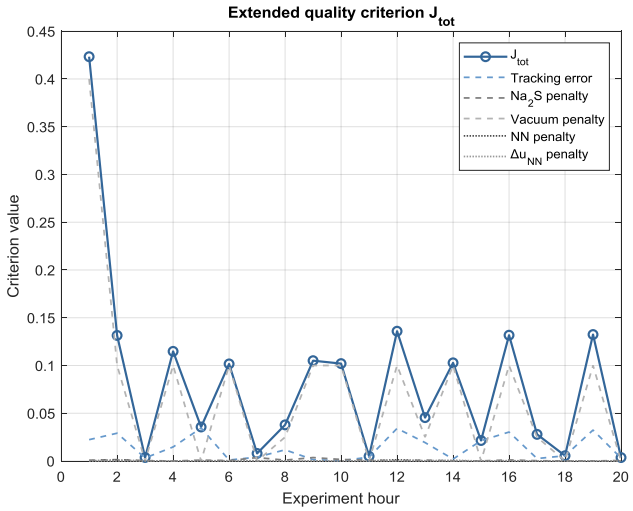


Figure 10. *Динамика критерия* Jtot и его составляющих в процессе эксперимента

Из графика видно, что на начальном этапе (первые часы, шаги ISD–ML) преобладает вклад ошибки слежения, связанный с выходом системы на эталон. На этапе OP корректировки Na_2S и поддержание вакуума обеспечивают снижение штрафов за управляющие воздействия. При включении FPA значения штрафов, связанных с нейросетевым каналом (u_{NN} и Δu_{NN}), остаются ограниченными, что подтверждает корректность выбранных коэффициентов регуляризации. Уже после 3-4 шагов J_{tot} стабилизируется на низком уровне, демонстрируя, что алгоритм в режиме скользящего горизонта обеспечивает устойчивое качество очистки при сбалансированных управляющих воздействиях. Таким образом, график иллюстрирует согласованность работы всех этапов предложенного гибридного MPC [15,17].

При данных условиях обеспечивается степень очистки кислоты от $As(III), As(V), Pb(II)$ выше 95 %, а значения критерия качества остаются стабильными при внешних возмущениях и изменении состава исходного сырья. Это подтверждает, что гибридный алгоритм MPC с GA и нейросетевой коррекцией обеспечивает как высокое качество конечного продукта, так и экономичность процесса за счёт оптимального использования реагентов [19,27].

Conclusion

В настоящей работе предложен предиктивный алгоритм управления для многомерных промышленных процессов, основанный на интеграции цифрового двойника, модели предиктивного управления (MPC), генетического алгоритма (GA) и нейросетевой коррекции (NN). Разработанная архитектура реализует двухканальное управление в замкнутом контуре по последовательности ISD–ML–OP–FPA: от сбора и нормализации данных до прогнозирования, оптимизации и онлайн-адаптации.

Цифровой двойник не только симулирует поведение процесса, но и служит активным элементом управляющего контура, что выводит разработку за пределы традиционных цифровых моделей. Виртуальная модель постоянно обновляется по данным с физического объекта (через PLC и теги), а нейросеть уточняет предска-

зания и компенсирует нелинейные эффекты. Благодаря встроенным механизмам регуляризации, влияние обучаемого канала строго ограничено, что повышает робастность и предсказуемость поведения регулятора.

На примере промышленного процесса очистки ортофосфорной кислоты показано, что гибридный регулятор достигает степени очистки до 95,1% по сравнению с 91,2% у базовой схемы MPC, уменьшает амплитуды колебаний управляющих сигналов примерно на 10–15% и сохраняет устойчивость при флуктуациях состава сырья и внешних возмущениях. Тем самым подход сочетает преимущества физического моделирования, предиктивного управления и методов машинного обучения в единой цифровой платформе и подтверждает применимость в задачах интеллектуальной автоматизации, где критичны точность, соблюдение технологических ограничений и адаптивность к изменчивым условиям производства [6].

Дальнейшее развитие исследований будет направлено на развитие методов цифрового двойника на более сложные MIMO-системы с запаздываниями и переменной структурой, формулировке многокритериальных постановок, объединяющих качество продукта, энергопотребление и безопасность, а также в интеграции с облачными и периферийными платформами управления и аналитики.