ISSN: 3030-3346

РОБАСТНАЯ ИИ-ОПТИМИЗАЦИЯ УПРАВЛЕНИЯ РЕКТИФИКАЦИОННОЙ КОЛОННОЙ В УСЛОВИЯХ НЕОПРЕДЕЛЁННОСТИ С ИСПОЛЬЗОВАНИЕМ ОБЪЯСНИМЫХ ГИБРИДНЫХ МОДЕЛЕЙ

Дошанова Малика Юлдашевна

доцент Ташкентского университета информационных технологий имени Мухаммада аль-Хорезми

E-mail: yuldashevna.m@gmail.com

K E Y W O R D S

ректификационная колонна; робастное управление; DMC; MPC под неопределённостью; гибридные модели; физически-информированное машинное обучение; объяснимый ИИ; SHAP; reference governor; Wood–Berry

A B S T R A C T

В работе предложен гибридный объяснимый робастный регулятор на основе динамической матрицы, объединяющий физически интерпретируемую линейную модель колонны с ансамблевой нейросетевой моделью невязок, обучаемой предсказывать систематическое рассогласование модель–объект и его эпистемическую неопределённость. Оценка неопределённости используется: для адаптивного демпфирования управляющих воздействий и для формирования безопасного диапазона уставок с гарантией отступа от технологических ограничений. Интерпретируемость поправки обеспечивается методом SHAP. Работоспособность подхода продемонстрирована на эталонной двухконтурной модели колонны с добавленной параметрической неопределённостью и нелинейностью исполнительных клапанов. Результаты 40-реализационного статистического эксперимента показывают, что при агрессивном запросе уставки предложенный регулятор снижает частоту нарушения ограничения с 100 % до 45 %, а среднюю величину превышения – более чем в 25 раз, ценой умеренного увеличения интегральной ошибки слежения в номинальном режиме – классический и ожидаемый компромисс между средней эффективностью и робастностью к худшему случаю.

Введение

Ректификация остаётся энергетически наиболее затратным процессом разделения в нефтепереработке и нефтехимии, а качество регулирования состава дистиллята и кубового продукта напрямую определяет как экономическую эффективность установки, так и соответствие продукции спецификациям. Классический подход к автоматизации колонны опирается на децентрализованные ПИД-контуры либо на линейный многомерный MPC/DMC [17, 19, 27, 25], синтезированный по идентифицированной передаточной модели объекта. Оба подхода сталкиваются с фундаментальным ограничением: эффективность регулятора обусловлена точностью используемой модели, тогда как реальная колонна демонстрирует нестационарность коэффициентов передачи из-за изменения нагрузки, состава сырья, загрязнения тарелок и нелинейности гидравлики и клапанной арматуры [26, 28].

Два направления развития промышленного управления процессами последних лет – робастная и стохастическая оптимизация MPC под явно заданной неопределённостью модели и применение методов машинного обучения для компенсации немоделируемой динамики рассматриваются раздельно [29], [33]. Чисто робастные формулировки (min-max MPC, tube-MPC, scenario-MPC) консервативны и не

(cc) BY

используют информацию, извлекаемую из данных эксплуатации, тогда как чисто ИИ-регуляторы (end-to-end нейросетевые политики) непрозрачны, требуют больших объёмов данных и не дают формальных гарантий устойчивости и ограничений качества продукта – что критично для регламентированных химических производств.

В данной работе рассматриваю третий путь – гибридную архитектуру, в которой физически интерпретируемая линейная модель объекта остаётся структурным ядром регулятора (и, соответственно, носителем гарантий и интерпретируемости), а компактная ансамблевая нейросетевая надстройка решает две узкие, хорошо обусловленные задачи: (i) предсказание систематического рассогласования модель–объект, обусловленного нелинейностью и параметрическим дрейфом, и (ii) количественную оценку эпистемической неопределённости этого предсказания, используемую для робастизации закона управления. Дополнительно, поскольку внедрение ИИ-компонент в регламентированные производства требует объяснимости принимаемых решений, вклад входных переменных в предсказанную поправку анализируется методом SHAP (SHapley Additive exPlanations) [9, 19].

Динамическое матричное управление (Dynamic Matrix Control, DMC) было предложено как модельно-предиктивный подход, использующий пошаговые отклики объекта, и получило широкое промышленное распространение благодаря простоте настройки и естественной компенсации постоянного смещения модель–объект через измеряемую обратную связь. Классической эталонной моделью для тестирования многомерных регуляторов колонн служит идентифицированная линейная модель двухконтурной ректификационной колонны [1-8], включающая значительное взаимное влияние контуров реализуемое через матрицу передаточных функций с существенными транспортными запаздываниями; для неё также разработана классическая децентрализованная ПИ-настройка, обеспечивающая одинаковый запас устойчивости обоих контуров (метод, известный как BLT-настройка) [4, 11-16].

Робастные расширения MPC – от классической формулировки min-max по Беммпораду и Морари до scenario-based и tube-based MPC – обеспечивают формальные гарантии соблюдения ограничений при ограниченном множестве неопределённости ценой консервативности и вычислительной сложности при росте горизонта и размерности множества сценариев [6, 24]. Гибридизация физических моделей с методами машинного обучения (physics-informed / residual learning) в последние годы активно применяется для компенсации немоделируемой динамики при сохранении структурных гарантий физической модели, а количественная оценка эпистемической неопределённости ансамблевыми методами используется как естественный источник информации для адаптивной робастизации закона управления [7, 23]. Наконец, объяснимость (XAI) для регуляторов, включающих ИИ-компоненты, всё чаще признаётся необходимым условием их промышленного внедрения в регламентированных отраслях, а метод аддитивных объяснений на основе значений Шепли (SHAP) стал де-факто стандартом атрибуции вклада признаков для моделей произвольной структуры [15, 21].

Объект исследования: модель ректификационной колонны

В качестве объекта регулирования рассматривается бинарная ректификационная колонна, динамика которой в окрестности рабочей точки описывается системой уравнений материального и покомпонентного баланса по тарелкам (MESH-уравнения: Material balance, Equilibrium, Summation, Heat balance), линеаризованных и идентифицированных в виде матричной передаточной функции «вход–выход». Управляемые переменные – состав дистиллята x_D и состав кубового продукта x_B (отклонения, мол. %); управляющие воздействия – расход флегмы R и расход греющего пара (кипятильника) S, измеряемое возмущение – расход сырья F. В работе используется классическая идентифицированная модель такой колонны (модель Wood–Berry),

(cc) BY

являющаяся общепринятым эталоном для тестирования многосвязных регуляторов колонн:

$$x_D(s) = G_{11}(s)R(s) + G_{12}(s)S(s) + G_{13}(s)F(s),$$
$$x_B(s) = G_{21}(s)R(s) + G_{22}(s)S(s) + G_{23}(s)F(s) \quad (1)$$

где каждый канал имеет вид апериодического звена первого порядка с транспортным запаздыванием:

$$G_{ij}(s) = \frac{K_{ij}e^{-\theta_{ij}s}}{\tau_{ij}s+1}. \quad (2)$$

Номинальные значения коэффициентов передачи K_{ij} (мол. %), постоянных времени τ_{ij} (мин) и запаздываний θ_{ij} (мин) соответствуют исходной идентификации: $K_{11} = 12.8$, $\tau_{11} = 16.7$, $\theta_{11} = 1.0$; $K_{12} = -18.9$, $\tau_{12} = 21.0$, $\theta_{12} = 3.0$; $K_{13} = 3.8$, $\tau_{13} = 14.9$, $\theta_{13} = 8.1$; $K_{21} = 6.6$, $\tau_{21} = 10.9$, $\theta_{21} = 7.0$; $K_{22} = 6.6$, $\tau_{22} = 14.4$, $\theta_{22} = 3.0$; $K_{23} = 4.9$, $\tau_{23} = 13.2$, $\theta_{23} = 3.4$. Транспортные запаздывания в цифровой реализации моделируются аппроксимацией Паде 3-го порядка с последующей дискретизацией с периодом квантования $T_s = 1$ мин методом фиксатора нулевого порядка (ZOH), что даёт точную дискретную модель состояния для каждого из шести SISO-каналов и итоговую MIMO-модель объекта как их суперпозицию (в силу линейности).

Данная модель отличается сильным перекрёстным взаимодействием контуров (число обусловленности матрицы статических коэффициентов передачи существенно больше единицы) и является общепризнанно «жёстким» тестовым примером для многосвязного управления, что делает её пригодной эталонной задачей для демонстрации робастности предлагаемого подхода.

Постановка задачи управления под параметрической неопределённостью

Истинный объект управления отличается от номинальной идентифицированной модели неизвестным набором параметров $\theta = \{K_{ij}, \tau_{ij}, \theta_{ij}\} \in \Theta$, где Θ – компактное множество неопределённости (в работе – гиперпараллелепипед относительных отклонений ±20 % по коэффициентам передачи, ±20 % по постоянным времени и ±25 % по запаздываниям от номинальных значений), а также нелинейностью статической характеристики регулирующих клапанов, не учитываемой номинальной линейной моделью:

$$x_{k+1} = A(\theta)x_k + B(\theta)u_k + B_d(\theta)F_k y_k = C(\theta)x_k, \quad \theta \in \Theta \quad (3)$$

тогда как регулятор оперирует номинальной моделью:

$$\hat{x}_{k+1} = \hat{A}\hat{x}_k + \hat{B}\hat{u}_k + \hat{B}_d F_k, \quad \hat{y}_k + \hat{C}\hat{x}_k. \quad (4)$$

Задача робастной оптимизации управления в общем виде формулируется как минимизация показателя качества в наихудшем случае по множеству неопределённости при соблюдении ограничений качества продукта (диапазон допустимых отклонений составов Y) для всех допустимых реализаций θ:

$$u_k^* = arg \min_{u \in U} \max_{\theta \in \Theta} J(x_k, u, \theta)\ s.t.\ y_{k+i}(\theta) \in \mathcal{Y}, \quad \forall \theta \in \Theta, i = 1, \dots, P \quad (5)$$

Точное решение задачи (1) для непрерывного множества Θ вычислительно неподъёмно в реальном времени при малом периоде квантования технологического объекта. В работе используется практически реализуемая аппроксимация: вместо явного min-max по θ используется (а) физическая номинальная модель как ядро предиктора, (б) статистически обученная поправка, аппроксимирующая ожидаемое рассогласование $E[y(\theta) - \hat{y}]$ по множеству Θ, и (в) явная количественная оценка дисперсии этого рассогласования $\sigma(\theta)$, используемая для перехода от жёсткого ограничения к его вероятностному (chance-constrained) аналогу:

$$P(y_{k+i} > y^{max}) \le \varepsilon \Leftarrow y_{k+i} \le y^{max} - z_{1-\varepsilon}\sigma_{k+i} \quad (6)$$

где $z_{1-\varepsilon}$ – квантиль стандартного нормального распределения, соответствующий заданному уровню доверия

$(1-\varepsilon)$. Такая формулировка сводит трудноразрешимую робастную задачу к детерминированной задаче с «отступом» (back-off) от границы ограничения, пропорциональным оценённой неопределённости – стандартный и вычислительно эффективный приём робастного MPC.

Предлагаемый гибридный объяснимый робастный регулятор

Архитектура предлагаемого регулятора строится поверх классической схемы динамического матричного управления (DMC) и включает четыре компоненты: физическую номинальную модель для прогноза свободного движения, ансамблевую нейросетевую модель невязок, робастное взвешивание хода управления и объяснимый reference governor.

На каждом шаге k свободный отклик номинальной модели $\hat{y}_{k+i|k}$ на горизонте предсказания P корректируется, во-первых, стандартной для DMC поправкой на измеренное смещение $(y_k - \hat{y}_k)$, обеспечивающей астатизм замкнутого контура, и, во-вторых, дополнительной feed-forward поправкой f_ϕ, предсказываемой нейросетевой моделью невязок по текущим значениям управляющих воздействий и измеряемого возмущения:

$$\tilde{y}_{k+i|k} = \hat{y}_{k+i|k} + (y_k - \hat{y}_k) + f_\phi(u_k, F_k),\ i = 1, \dots, P, \qquad (7)$$

Модель f_ϕ реализована в виде ансамбля из L=6 полносвязных нейронных сетей (2 скрытых слоя по 16 нейронов, активация tanh), обученных на бутстреп-выборках из данных, полученных в результате замкнутых прогонов номинального DMC-регулятора против набора возмущённых реализаций объекта (варьирование $\theta \in \Theta$ и коэффициента нелинейности клапана γ). Средний прогноз и его ансамблевое стандартное отклонение вычисляются как:

$$f_\phi(z) = \frac{1}{L}\sum_{l=1}^{L} f_{\phi_l}(z)$$
$$\sigma(z) = \sqrt{\frac{1}{L}\sum_{l=1}^{L}(f_{\phi_l}(z) - f_\phi(z))^2} \qquad (8)$$

Признаковое пространство модели невязок ограничено манипулируемыми и измеряемыми переменными (R, S, F) – без прямой зависимости от текущего измеряемого выхода y_k, – что предотвращает образование паразитного алгебраического контура обратной связи «через невязку» и связанную с ним неустойчивость: в предварительных экспериментах включение y_k в вектор признаков приводило к колебательному, а в отдельных случаях – расходящемуся переходному процессу из-за неверно скомпенсированной фазы поправки относительно транспортного запаздывания объекта. По той же причине итоговая поправка f_ϕ фильтруется экспоненциальным сглаживающим фильтром первого порядка перед использованием в законе управления.

Функция цели DMC на скользящем горизонте прогнозирования P с горизонтом управления M принимает вид:

$$J_k = \sum_{i=1}^{P}\left\|\tilde{y}_{k+i|k} - r_{k+i}\right\|_Q^2 + \sum_{j=0}^{M-1}\left\|\Delta u_{k+j}\right\|_{\Lambda(\sigma)}^2, \qquad (9)$$

где Q – весовая матрица штрафа за отклонение от уставки, а $\Lambda(\sigma)$ – матрица штрафа за приращение управления (аналог демпфирования хода), адаптивно увеличиваемая пропорционально ансамблевой неопределённости:

$$\Lambda(\sigma) = \lambda_0 I + \beta\, diag(\sigma). \qquad (10)$$

Такая формулировка реализует эвристику осторожного управления (cautious control): в режимах, для которых обучающая выборка малоинформативна (высокое σ, т.е. режим слабо покрыт историей эксплуатации), регулятор автоматически становится более консервативным, снижая агрессивность управляющих движений. Решение задачи (4) при отсутствии активных ограничений на управление имеет явный вид:

$$\Delta u_k^* = (G^T Q G + \Lambda(\sigma))^{-1} G^T Q (r - \tilde{y}_{free}), \qquad (11)$$

где G – динамическая матрица номинальной модели, построенная из коэффициентов её ступенчатой переходной характеристики. Найденное приращение Δu_k

(cc) BY

проецируется на допустимые физические диапазоны хода клапанов и скорости их перемещения (насыщение и ограничение скорости изменения).

Помимо адаптивного демпфирования, оценённая неопределённость σ используется для явного управления запросом уставки: если оператор или верхний уровень оптимизации запрашивают уставку r_k, потенциально приближающую состав продукта к технологическому пределу y^{max}, регулятор ограничивает фактически используемое задание безопасным диапазоном:

$$r_k^{safe} = sat(r_k;\ -(y^{max} - z\sigma_k), y^{max} - z\sigma_k). \quad (12)$$

Данный механизм – частный случай классического reference governor – не изменяет структуру решаемой на каждом шаге задачи DMC (4)–(5), а модифицирует лишь подаваемую на вход уставку, что делает его вычислительно тривиальным и устойчивым к численным артефактам (в отличие от опробованной в ходе разработки альтернативы – прямой онлайн-проекции найденного хода на прогнозируемую траекторию, – которая при значительной неопределённости модели приводила к нежелательным колебаниям и не гарантировала соблюдения ограничения по факту, поскольку опиралась на прогноз той же номинальной модели, чью погрешность и требовалось компенсировать).

Поскольку решения, принимаемые нейросетевой надстройкой, напрямую влияют на управляющее воздействие в регламентированном технологическом процессе, вклад каждой входной переменной в предсказанную величину невязки f_ϕ количественно оценивается методом аддитивных объяснений Шепли (SHAP). Для произвольной обучаемой функции f_ϕ метод строит аддитивное разложение прогноза по признакам:

$$f_\phi(z) = \phi_0 + \sum_{j=1}^{n} \phi_j(z), \quad (13)$$

где ϕ_0 – базовое (среднее) значение прогноза, а ϕ_j – вклад j-го признака (R, S или F) в отклонение прогноза от базового для конкретного режима работы колонны. В работе использован KernelExplainer (модельно-агностичная аппроксимация значений Шепли на основе локальной линейной регрессии с ядром Шепли) применительно к усреднённому прогнозу ансамбля.

Численный эксперимент

Для количественной оценки предложенного подхода реализованы три контура сравнения на общей «истинной» модели объекта: (i) базовый децентрализованный ПИ-регулятор с классической BLT-настройкой ($K_{c1} = 0.375$, $T_{i1} = 8.29$ мин; $K_{c2} = -0.075$, $T_{i2} = 23.6$ мин), не использующий модель объекта; (ii) номинальный DMC-регулятор (горизонт прогноза P=20 мин, горизонт управления M=3, вес демпфирования $\lambda_0 = 6$) на номинальной линейной модели без учёта неопределённости; (iii) предложенный гибридный объяснимый робастный регулятор HER-DMC (та же номинальная модель и базовые веса DMC, дополненные ансамблевой поправкой, робастным демпфированием ($\beta = 8$) и reference governor'ом с уровнем доверия $z = 1.65$, соответствующим одностороннему 95%-ному запасу).

«Истинный» объект в каждой реализации Монте-Карло формируется независимым случайным сэмплированием параметров θ из равномерного распределения в границах неопределённости и случайным коэффициентом нелинейности статической характеристики клапанов γ_R, $\gamma_S \in [0; 0.15]$ (модель нелинейности вида $u_{eff} = u + \gamma\, u\,|u|/u_{scale}$, характерная для реальной установленной характеристики регулирующего клапана). Обучающая выборка для ансамблевой модели невязок сформирована на независимом наборе из 30 таких реализаций (без пересечения с тестовыми реализациями, используемыми для итоговой оценки), что исключает утечку данных между обучением и тестированием.

Оцениваемые показатели качества – интегральная абсолютная (IAE) и квадратичная (ISE) ошибки слежения, накопленные за интервал моделирования T=220 мин:

(cc) BY

$$IAE = \sum_k \|r_k - y_k\|_1,\ ISE = \sum_k \|r_k - y_k\|_2^2, \quad (17)$$

а также частота и величина нарушения технологического ограничения $|x_D| \le y^{max} = 2.2$ мол.% в сценарии агрессивного запроса уставки, заведомо превышающей допустимый предел.

Результаты

На рис. 1 приведён характерный переходный процесс всех трёх регуляторов на одной из тестовых реализаций неопределённости (не использованной при обучении модели невязок), включающий два скачка уставки и ступенчатое возмущение по расходу сырья.

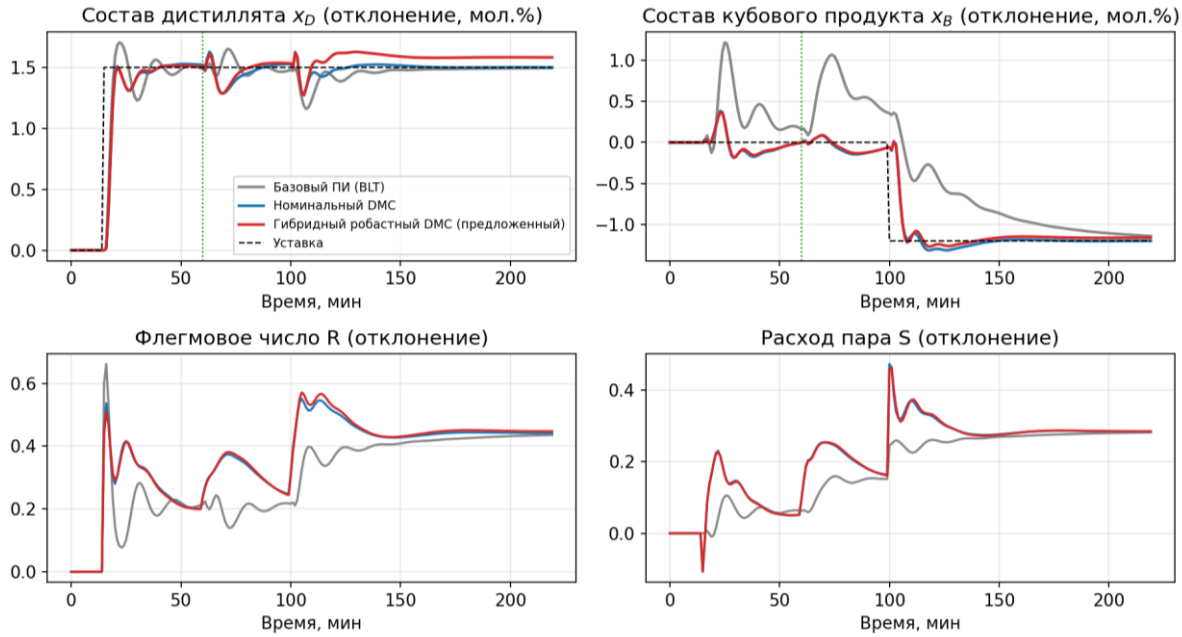


Рис. 1. Переходные процессы по составу дистиллята x_D, составу куба x_B и управляющим воздействиям (R, S).

Номинальный DMC демонстрирует заметно более быструю и точную отработку заданий по сравнению с ПИ-регулятором благодаря учёту многомерного взаимодействия контуров и явному прогнозированию; гибридный регулятор сохраняет качественно аналогичную динамику, при этом его управляющие воздействия несколько более сглажены за счёт адаптивного демпфирования.

Табл. 1 обобщает результаты 40 независимых реализаций параметрической неопределённости и нелинейности клапанов для номинального сценария слежения за уставкой (без превышения технологических ограничений). Номинальный DMC превосходит гибридный регулятор по среднему и медианному значению IAE/ISE – ожидаемый результат (Рис. 2), поскольку робастизация (адаптивное демпфирование и консервативная feed-forward поправка) намеренно снижает агрессивность управления. При этом статистика худшего случая (95-й процентиль, максимум) и стандартное отклонение IAE у гибридного регулятора ниже, чем у номинального DMC, что указывает на более предсказуемое, менее подверженное «выбросам» поведение при неблагоприятном сочетании параметров объекта – типичный и ожидаемый компромисс «средняя эффективность / робастность к худшему случаю», характерный для робастных методов управления в целом.

(cc) BY

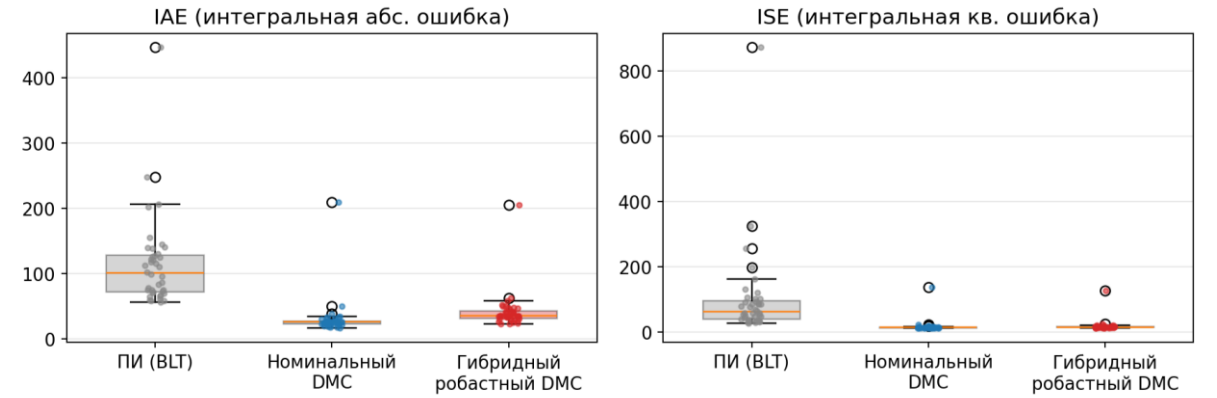


Рис. 2. Распределение показателей IAE и ISE

Таблица. 1.

Сводная статистика показателей качества слежения по 40 реализациям неопределённости (T = 220 мин).

Показатель	**Регулятор**	**Среднее**	**СКО**	**95-й перц.**	**Худший случай (max)**
IAE	ПИ (BLT)	114.2	68.5	208.5	446.3
IAE	Номинальный DMC	30.4	29.3	38.6	209.3
IAE	HER-DMC (предл.)	41.5	27.8	58.9	205.1
ISE	ПИ (BLT)	101.7	137.9	260.9	873.5
ISE	Номинальный DMC	18.2	19.3	19.4	138.3
ISE	HER-DMC (предл.)	19.4	17.6	21.6	128.2

Практическая ценность робастизации наиболее отчётливо проявляется в сценарии, когда запрошенная (например, оператором верхнего уровня оптимизации) уставка по составу дистиллята заведомо превышает технологический предел ($y^{max} = 2.2$ мол.%, запрошено $r = 2.6$ мол.%) – ситуация, реалистичная при неверной оценке технологического запаса или при агрессивной экономической оптимизации без учёта неопределённости модели. Табл. 2 и рис. 3 показывают, что ни базовый ПИ-регулятор, ни номинальный DMC не обладают встроенным механизмом защиты от подобного запроса и в 100 % из 40 тестовых реализаций допускают превышение предела; номинальный DMC при этом демонстрирует даже больший максимальный выброс (0.92 мол.%), чем ПИ, поскольку его более быстрая динамика ближе подводит траекторию к пределу до момента, когда обратная связь успевает её скорректировать.

Гибридный регулятор с reference governor'ом, ограничивающим фактическое задание безопасным диапазоном, пропорциональным оценённой неопределённости, нарушает ограничение лишь в 45 % реализаций (за счёт остаточной динамической ошибки при ступенчатом возмущении, не связанной с самим запросом уставки), а среднее превышение предела снижается более чем в 25 раз (с ≈0.57–0.58 до ≈0.02 мол.%), максимальное – с 0.92 до 0.10 мол.%.

(cc) BY

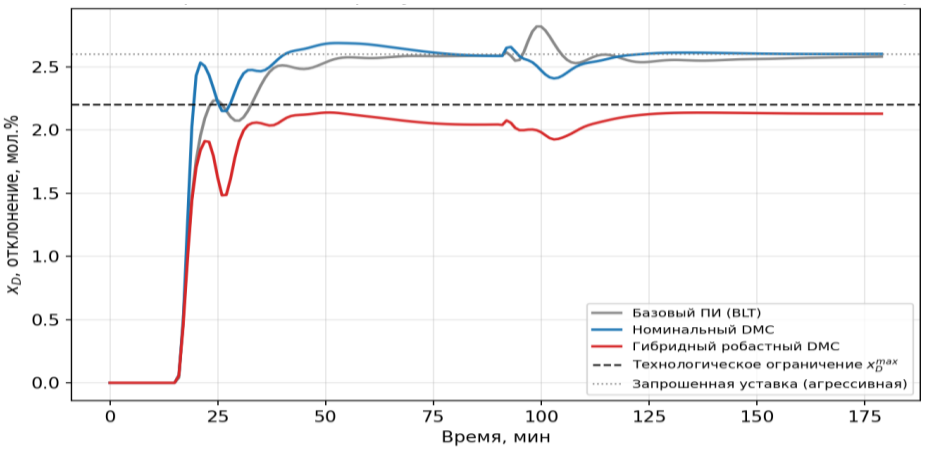


Рис. 3. Реакция на запрос уставки, заведомо превышающей технологический предел x_D^{max} (штриховая линия).

Таблица 2.

Соблюдение технологического ограничения |x_D| ≤ 2.2 мол.% при запросе агрессивной уставки r = 2.6 мол.%.

Регулятор	**Доля нарушений, %**	**Среднее превышение, мол.%**	**Макс. превышение, мол.%**
ПИ (BLT)	100	0.581	0.732
Номинальный DMC	100	0.566	0.923
HER-DMC (предл.)	45	0.021	0.105

Рис. 4 представляет средние абсолютные значения Шепли для трёх входных признаков модели невязок (R, S, F) отдельно для предсказания невязки по x_D и по x_B. Результат физически интерпретируем и согласуется со структурой введённой в модель нелинейности: расход флегмы R оказывается доминирующим фактором предсказанного рассогласования по составу дистиллята x_D (контур, напрямую связанный с R), тогда как расход греющего пара S доминирует для рассогласования по составу куба x_B (контур, напрямую связанный с S); вклад возмущения по сырью F стабильно умеренный и сопоставим по обоим выходам, что соответствует симметричному влиянию измеряемого возмущения на оба контура через каналы G13 и G23 модели. Подобный анализ, помимо содействия доверию технологического персонала к рекомендациям гибридного регулятора, может использоваться как диагностический инструмент для приоритизации работ по перекалибровке модели или обслуживанию конкретного исполнительного механизма.

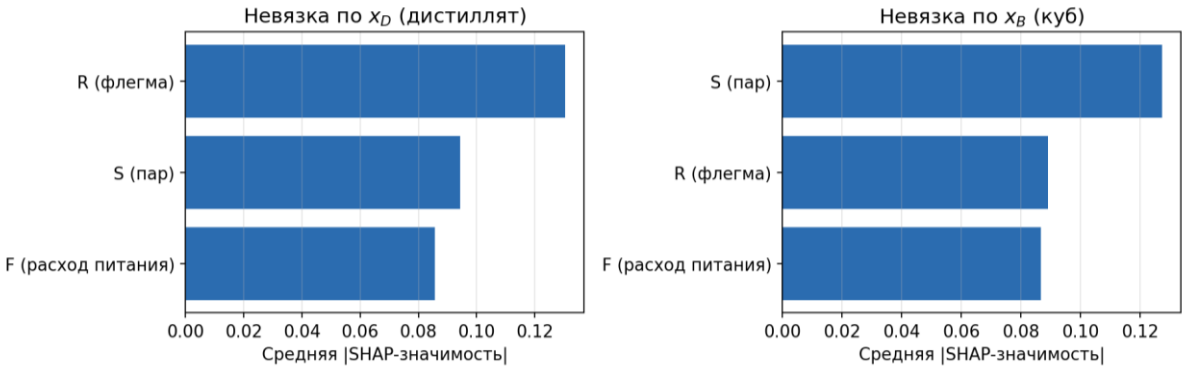


Рис. 4. Средняя абсолютная значимость (SHAP) входных переменных R, S, F в предсказанном рассогласовании модель – объект для каналов x_D и x_B.

(cc) BY

Обсуждение

Полученные результаты подтверждают ожидаемый и хорошо документированный в литературе по робастному управлению компромисс: механизмы, повышающие устойчивость к худшему случаю, закономерно снижают агрессивность и, как следствие, среднюю эффективность регулятора в номинальном режиме эксплуатации. Ценность предложенного подхода состоит не в безусловном превосходстве по всем метрикам одновременно, а в том, что степень консервативности определяется не фиксированным заранее параметром настройки, а данными – эпистемической неопределённостью, извлекаемой из ансамбля моделей, обученных на реализациях эксплуатации объекта. Это отличает предложенную схему как от классического робастного MPC с фиксированным множеством неопределённости, так и от чисто ИИ-регуляторов без встроенных гарантий соблюдения технологических ограничений.

Следует явно указать на ограничения представленного исследования. Во-первых, численные эксперименты выполнены на линейной эталонной модели колонны (Wood–Berry) с добавленной параметрической неопределённостью и локальной статической нелинейностью клапанов; коэффициент детерминации ансамблевой модели невязок ($R^2 \approx 0.62–0.67$) отражает то обстоятельство, что предсказание рассогласования по столь ограниченному признаковому пространству (без учёта измеряемого выхода, что было намеренным архитектурным решением для предотвращения паразитной обратной связи) объективно оставляет существенную необъяснённую дисперсию; более богатое признаковое пространство (например, включающее фильтрованные или запаздывающие оценки выхода, не создающие мгновенного алгебраического контура) потенциально способно повысить точность поправки. Во-вторых, эксперимент выполнен на единственном классе объекта и единственной структуре неопределённости; обобщение выводов на колонны иной структуры (многокомпонентная ректификация, боковые отборы, иные схемы регулирования) требует отдельной валидации. В-третьих, предложенный DMC использует приближённое (без явного решения задачи квадратичного программирования с ограничениями на всём горизонте) вычисление закона управления в замкнутой форме с последующим насыщением; для промышленного внедрения обоснованным развитием является интеграция предложенной гибридной модели и робастного взвешивания непосредственно в постановку задачи квадратичного программирования с явными ограничениями на выход.

Направления дальнейших исследований включают: (а) явную scenario-based формулировку робастного MPC поверх предложенной гибридной модели с решением задачи выпуклого программирования на каждом шаге; (б) расширение признакового пространства модели невязок с сохранением каузальной структуры, исключающей алгебраические контуры; (в) валидацию на данных реальной промышленной установки или на модели с явной нелинейностью равновесия пар–жидкость (в отличие от линеаризованной модели Wood–Berry); (г) исследование альтернативных мер эпистемической неопределённости (байесовские нейронные сети, conformal prediction) как источника адаптивного демпфирования и back-off.

Заключение

В работе предложена и количественно валидирована гибридная объяснимая архитектура робастного управления составом продуктов ректификационной колонны под параметрической неопределённостью модели и нелинейностью исполнительных механизмов. Архитектура сохраняет физически интерпретируемую линейную модель объекта в качестве структурного ядра регулятора и дополняет её ансамблевой нейросетевой моделью невязок, оценка неопределённости которой используется для адаптивного демпфирования управляющих воздействий и для объяснимого механизма ограничения запроса уставки. На эталонной модели колонны Wood–Berry показано, что предложенный подход обеспечивает существенно более надёжное соблюдение технологических ограничений при

(cc) BY

агрессивном запросе уставки (снижение доли нарушений со 100 % до 45 % и средней величины превышения – более чем в 25 раз) ценой умеренного снижения средней эффективности слежения в номинальном режиме – результат, согласующийся с общими принципами робастного управления. Метод SHAP применён для содержательной интерпретации вклада технологических переменных в предсказанную гибридной моделью поправку, что способствует повышению доверия технологического персонала к рекомендациям регулятора и может использоваться как самостоятельный диагностический инструмент.

Литература

1. H. Ramezani and N. Sadati, “Hierarchical optimal control of a binary distillation column,” Chemical Engineering Science, vol. 28, pp. 1707-1717, 2018.
2. V. D. Ram and M. Chidambaram, “Simple method of designing centralized PI controllers for multivariable systems based on SSGM,” ISA Transactions, vol. 56, pp. 252-260, May 2015, doi: 10.1016/j.isatra.2014.11.019.
3. E. F. Camacho and C. Bordons, Model Predictive Control, 2nd ed. London, U.K.: Springer, 2007.
4. R. S. Gesser, D. M. Lima, and J. E. Normey-Rico, “Robust model predictive control: Implementation issues with comparative analysis,” IFAC-PapersOnLine, vol. 51, no. 25, pp. 478-483, 2018, doi: 10.1016/j.ifacol.2018.11.183.
5. S. V. Raković, “Robust model predictive control,” in Encyclopedia of Systems and Control, J. Baillieul and T. Samad, Eds. Cham, Switzerland: Springer, 2021, doi: 10.1007/978-3-030-44184-5_2.
6. J. B. Rawlings, D. Q. Mayne, and M. Diehl, Model Predictive Control: Theory, Computation, and Design, 2nd ed. Madison, WI, USA: Nob Hill Publishing, 2017.
7. S. M. Lundberg and S.-I. Lee, “A unified approach to interpreting model predictions,” in Advances in Neural Information Processing Systems (NeurIPS), vol. 30, 2017, pp. 4765-4774.
8. J. L. Garriga and M. Soroush, “Model predictive control tuning methods: A review,” Industrial & Engineering Chemistry Research, vol. 49, pp. 3505-3515, 2010.
9. J. Willard, X. Jia, S. Xu, M. Steinbach, and V. Kumar, "Integrating physics-based modeling with machine learning: A survey," arXiv preprint arXiv:2003.04919, 2020.
10. M. A. F. Martins, A. S. Yamashita, B. F. Santoro, and D. Odloak, "Robust model predictive control of integrating time delay processes," Journal of Process Control, vol. 23, no. 7, pp. 917-932, 2013, doi: 10.1016/j.jprocont.2013.05.002.
11. L. Jetto and V. Orsini, “Formulation of min-max model predictive control as a box-constrained robust least squares estimation problem,” IFAC-PapersOnLine, vol. 53, no. 2, pp. 7077-7084, 2020, doi: 10.1016/j.ifacol.2020.12.460.
12. D. Q. Mayne, “Robust and stochastic model predictive control: Are we going in the right direction?” Annual Reviews in Control, vol. 41, pp. 184-192, 2016.
13. L. Hewing, J. Kabzan, and M. N. Zeilinger, “Cautious model predictive control using Gaussian process regression,” IEEE Transactions on Control Systems Technology, vol. 28, no. 6, pp. 2736-2743, 2020.
14. L. Hewing, K. P. Wabersich, M. Menner, and M. N. Zeilinger, “Learning-based model predictive control: Toward safe learning in control,” Annual Review of Control, Robotics, and Autonomous Systems, vol. 3, pp. 269-296, 2020.
15. M. Schwenzer, M. Ay, T. Bergs, and D. Abel, “Review on model predictive control: An engineering perspective,” The International Journal of Advanced Manufacturing Technology, vol. 117, pp. 1327-1349, 2021.
16. A. Mesbah, K. P. Wabersich, A. P. Schoellig, M. N. Zeilinger, S. Lucia, and J. A. Paulson, “Fusion of machine learning and MPC under uncertainty: What advances are on the horizon?” in Proc. American Control Conference (ACC), 2022, pp. 342-357.
17. A. Sasfi, M. N. Zeilinger, and J. Köhler, “Robust adaptive MPC using control contraction metrics,” Automatica, vol. 155, Art. no. 111169, 2023.

(cc) BY *dtai.uz*

18. A. N. Angelopoulos and S. Bates, “A gentle introduction to conformal prediction and distribution-free uncertainty quantification,” arXiv preprint arXiv:2107.07511, 2022.
19. N. R. Yusupbekov, S. M. Gulyamov, and M. Y. Doshchanova, “Neural identification of a dynamic model of a technological process,” in 2019 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2019, pp. 1-5, doi: 10.1109/ICISCT47635.2019.9011912.
20. G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, “Physics-informed machine learning,” Nature Reviews Physics, vol. 3, no. 6, pp. 422-440, 2021.
21. Z. Wu, D. Rincon, and P. D. Christofides, “Process structure-based recurrent neural network modeling for model predictive control of nonlinear processes,” Journal of Process Control, vol. 89, pp. 74-84, 2020.
22. M. Elsheikh, Y. Ortmanns, F. Hecht, V. Roßmann, S. Krämer, and S. Engell, “Control of an industrial distillation column using a hybrid model with adaptation of the range of validity and an ANN-based soft sensor,” Chemie Ingenieur Technik, vol. 95, pp. 1114-1124, 2023.
23. S. Roy, S. Saha, B. Modak, F. Ahmed, A. Mahto, and S. K. Lahiri, “Enhanced fault detection and diagnosis in industrial distillation column using explainable artificial intelligence and machine learning,” International Journal of Prognostics and Health Management, vol. 16, no. 2, 2025.
24. A. Barredo Arrieta et al., “Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI,” Information Fusion, vol. 58, pp. 82-115, 2020.
25. N. R. Yusupbekov, S. M. Gulyamov, and M. Y. Doshchanova, “Neuro-fuzzy modeling for predictive control systems with complex technological processes and production,” Chemical Technology. Control and Management, no. 1, 2020.
26. M. Doshanova, O. Ruzibayev, S. Sabirov, and O. Begimov, “Operative-predictive control of a reactor plant based on fuzzy models,” SETSCI Conference Proceedings, vol. 17, pp. 34-39, 2024, doi: 10.36287/setsci.17.1.0034.

(cc) BY