

РЕАЛИЗАЦИЯ СИСТЕМЫ УПРАВЛЕНИЯ СТЕНДОМ С ИСПОЛЬЗОВАНИЕМ МОДЕЛИ ПРОГНОЗИРОВАНИЯ НА ОСНОВЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Феоктистова Д.А.¹, Седельникова Е.А.², Беляев А.С.³

¹ *Томский политехнический университет, Инженерная школа информационных технологий и робототехники 8Т12, e-mail: daf19@tpu.ru*

² *Томский политехнический университет, Инженерная школа информационных технологий и робототехники 8Т12, e-mail: eas144@tpu.ru*

³ *Томский политехнический университет, Инженерная школа информационных технологий и робототехники, к.т.н., старший преподаватель, e-mail: asb22@tpu.ru*

Аннотация

В статье рассмотрен метод получения моделей реального объекта на основе искусственного интеллекта и синтез системы управления на основе полученной модели. Работа направлена на изучение возможностей применения современных подходов к моделированию и управлению для повышения эффективности и точности управления сложными системами в различных областях.

Ключевые слова: системы управления, машинное обучение, нейронные сети, прогнозирование, состояние объекта.

Введение

Мир стремится к созданию "умных" заводов и предприятий, где машины и системы могут обмениваться данными и принимать решения автономно, а также, где процессы производства оптимизированы за счет анализа больших объемов данных.

Однако на текущий момент для автоматизации большинства производств используется стандартный ПИД-регулятор. Это можно объяснить простотой его реализации, стандартными методами настройки, применением для большого спектра задач. Но использование ПИД-регулятора для управления системами, содержащими такие характеристики, как: нелинейность, частичная неопределённость, нестационарные многосвязные объекты с временем запаздывания, может привести к нестабильным характеристикам управления, накоплению ошибок и, в конечном итоге, к ухудшению качества производства [1]. В связи с современными тенденциями перехода к комплексной автоматизации производства ПИД-регуляторы остаются исключительно лишь инструментами локальной автоматизации.

На уровне комплексной автоматизации производства (уровни ERP и MES) одним из самых популярных за последнее десятилетие стал метод управления на базе прогнозирующих моделей или Model Predictive Control. MPC контроллер особенно эффективен в системах с переменными и сложными динамическими условиями, где требуется точное управление и учет ограничений на входные и выходные переменные. Например, для производственного управления доменной печью [2]. В транспортных системах MPC может применяться для управления движением автомобилей или управления трафиком [3], что демонстрирует его работоспособность в сложных динамических средах. Принцип работы подобных регуляторов базируется на использовании модели объекта или системы, для предварительной проверки управляющего воздействия и анализа реакции системы на данное воздействие. То есть для синтеза подобной системы управления необходима модель объекта управления. Наиболее часто применяют математические модели, базирующиеся на физических, химических и иных законах. Однако получение подобных моделей для сложных систем (например, комплексного многоэтапного производства) сопряжено со сложностью описания не только процессов, протекающих внутри, но и верного учета влияния внутренних неопределенностей и внешних воздействий.

Альтернативным методом являются модели, полученные с использованием методов машинного обучения, которое, опираясь на реальные данные с производственных или физических установок, способно обобщать протекающие эффекты и явления для прогнозирования необходимых параметров без явного определения математических моделей или правил. Одним из наиболее часто применяемых методов машинного обучения являются нейронные сети (Neural Network). В управлении производством предпринимаются попытки применения нейросетевого прогнозирующего управления. Его основная идея заключается в том, что для прогноза динамики процесса используется не линейная

математическая модель, а модель, полученная на базе нейронной сети. В работе [4] эффективность данного подхода проверяется с помощью имитационных экспериментов, а в качестве управляемого процесса выбран трубчатый теплообменник.

Недостаток использования моделей, построенных с использованием машинного обучения – отсутствие физической закономерности в полученной зависимости, то есть, модель является исключительно математической, вследствие чего возможен неучет определенных параметров и ситуаций, влияющих на принцип работы системы. Кроме того, трудно сделать вывод о будущем качестве системы управления на базе таких моделей.

Поэтому в данной работе рассмотрен процесс получения модели реального объекта, например нелинейного, на основе метода искусственного интеллекта и последующего синтеза системы управления на основе данной модели. Также рассматривается вопрос об основных недостатках данных моделей и их влиянии на системы управления. Для этого необходимо реализовать следующие этапы исследования:

1. Создать математическую модель исследуемого объекта на основе дифференциальных уравнений в качестве источника эталонной информации.
2. Осуществить сбор информации с модели с учетом изменчивости внутренних параметров системы и вход-выходных состояний объекта.
3. Произвести обучение моделей с использованием машинного обучения для прогнозирования выходной величины.
4. Разработать и исследовать систему управления обратной связью из полученной модели.

Описание установки и составление структурной схемы

В качестве объекта управления был использован стенд, состоящий из двух сообщающихся сосудов, которые соединены трубопроводом с задвижкой с переменным коэффициентом k_{12} , сливного резервуара, регулирующих клапанов k_1, k_2 для слива из соответствующих резервуаров, а также насоса с частотным управлением. Внешний вид стенда приведен на рисунке 1.



Рис. 1. Установка сообщающихся сосудов

Система сообщающихся сосудов имеет следующее физическое описание в виде дифференциальных уравнений:

$$\begin{cases} \frac{dH_1(t)}{dt} = \frac{1}{S_1} \left[Q_{1\text{приток}}(t) - S_{\text{омс}} \sqrt{2g(H_2(t) - H_1(t))} - Q_{1\text{расх}}(t) \right] \\ \frac{dH_2(t)}{dt} = \frac{1}{S_2} \left[Q_{2\text{приток}}(t) - S_{\text{омс}} \sqrt{2g(H_2(t) - H_1(t))} - Q_{2\text{расх}}(t) \right] \end{cases}$$

где $Q_{1\text{приток}}(t), Q_{2\text{приток}}(t)$ – расходы притока; $Q_{1\text{расх}}(t), Q_{2\text{расх}}(t)$ – расходы оттоков; S_1, S_2 – сечения емкостей; H_1, H_2 – уровни жидкости в емкостях; $S_{\text{омс}}$ – сечение перетока.

Здесь величина, которая вытекает из сосуда $Q_{\text{ВЫЛ}} = v_{\text{ВЫЛ}} * S_{\text{ОТВ}}$, где $v_{\text{ВЫЛ}}$ выражается из закона Торичели. Закон гласит, что скорость вытекания $v_{\text{ВЫЛ}}$ жидкости через отверстие с острыми краями на

дне резервуара, заполненного на глубину h , равна скорости, которую приобрело бы тело при свободном падении с высоты h , т.е., $v = \sqrt{2gh}$ где g – ускорение под действием силы тяжести.

Построенная в MatLab Simulink структурная схема представлена на рисунке 2.

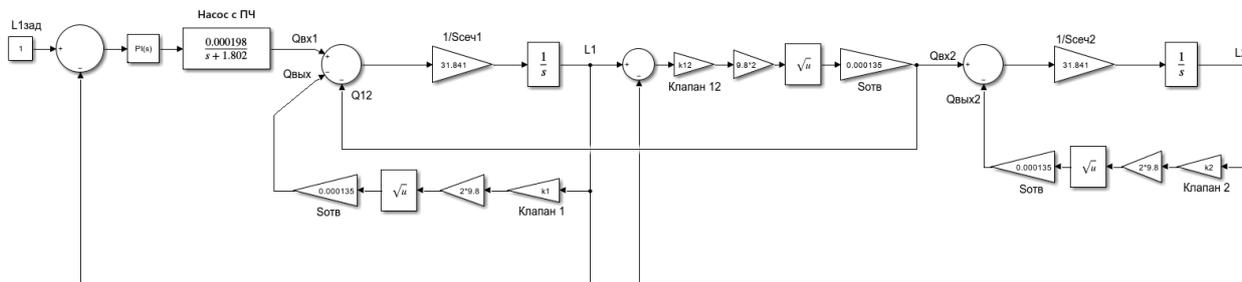


Рис. 2. Структурная схема системы сообщающихся сосудов

Синтез системы управления по уровню жидкости в первом сосуде позволяет стабилизировать как уровень в первом сосуде, так и во втором за счет свойства сообщающихся сосудов. Переходный процесс изображен на рисунке 3.

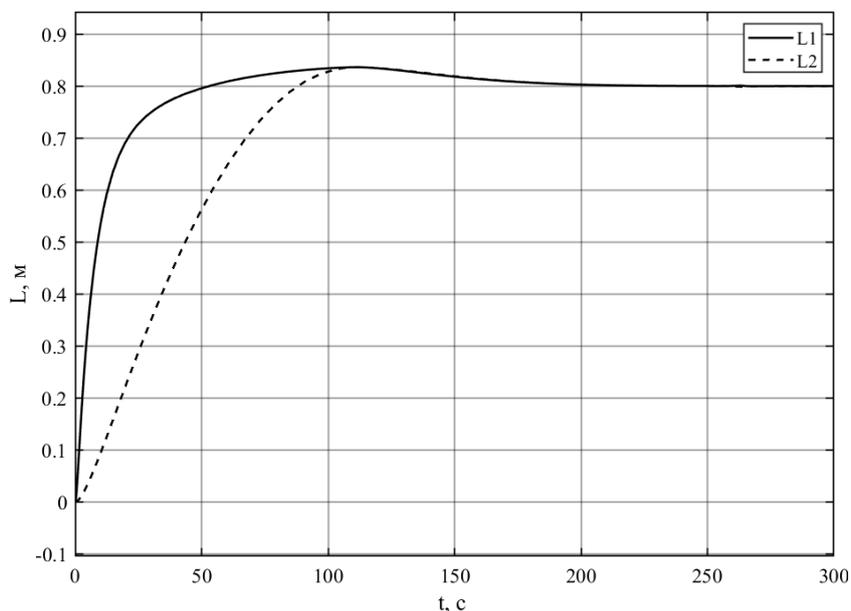


Рис. 3. Переходный процесс с коэффициентами $k_1=1$, $k_2=0$, $k_{12}=1$

Заданный уровень воды в первом сосуде достигается быстрее, чем уровень во втором сосуде, за счет подачи жидкости в первый сосуд. Данный переходный процесс демонстрирует работоспособность и адекватность полученной системы управления и математической модели.

Обучение моделей

Для реализации этапа обучения моделей с использованием методов машинного обучения были собраны параметры системы (количество жидкости, подаваемое в первый сосуд(Q), уровень воды в первом сосуде(L_1), уровень воды во втором сосуде(L_2)) при изменении коэффициентов k_1 , k_{12} , k_2 . На основе полученных данных были обучены модели, используя Regression Learner. При обучении модели $\Delta L_1(Q)$ входной переменной была Q – входной поток жидкости; при обучении модели $L_2(L_1)$ входными переменными являлись L_1 , k_1 , k_{12} , k_2 .

Для обучения использовались алгоритмы обучения такие, как: linear regression, narrow neural network, wide neural network. Лучшие результаты показал алгоритм wide neural network, зависимости изображены на рисунке 4, а; результаты ошибок моделей показаны в таблице 1.

Точностные меры

	$\Delta L1(Q)$	L2(L1)
$RMSE = \sqrt{\frac{1}{h} \sum_{i=1}^h (y_i - f_i)^2}$	0,0039283	0,10321
$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$	0,99	0,95

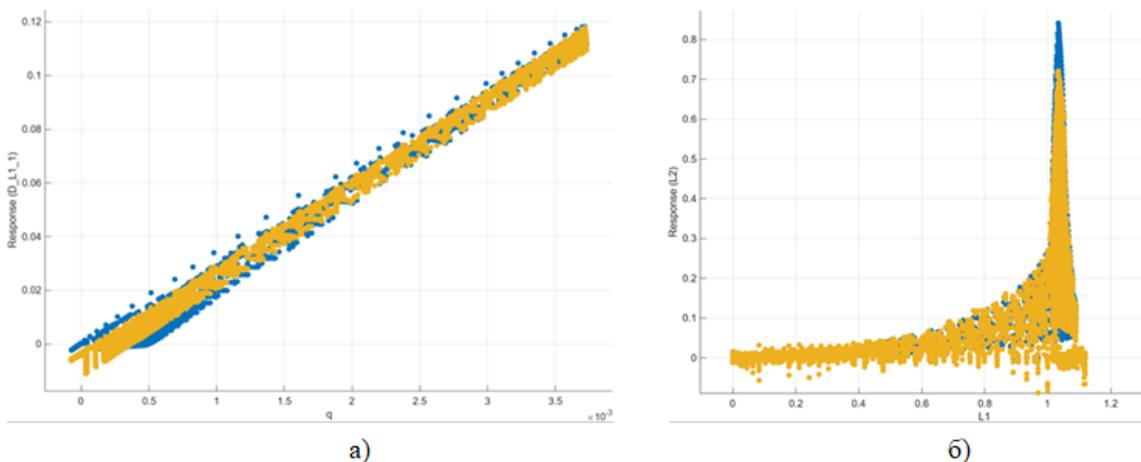


Рис. 4. Графики обучения для зависимостей (а – изменение L1 от входного потока; б - для зависимости L2 от L1)

На данном графике желтые точки – это предсказанные значения при обучении, синие точки – реальные значения с математической модели.

Следующим этапом стала проверка качества системы управления на базе ПИД- регулятора (с переходным процессом представленным на рисунке 3) с обратной связью из обученных моделей. Качество работы системы осуществлялось исключительно по уровню воды в первом сосуде (L1) в сравнении с работой регулятора с обратной связью по математической модели. В результате уровень воды в первом сосуде, который выдает нейронная сеть, представлен на рисунке 6, а переходный процесс уровня воды с физической модели – на рисунке 7.

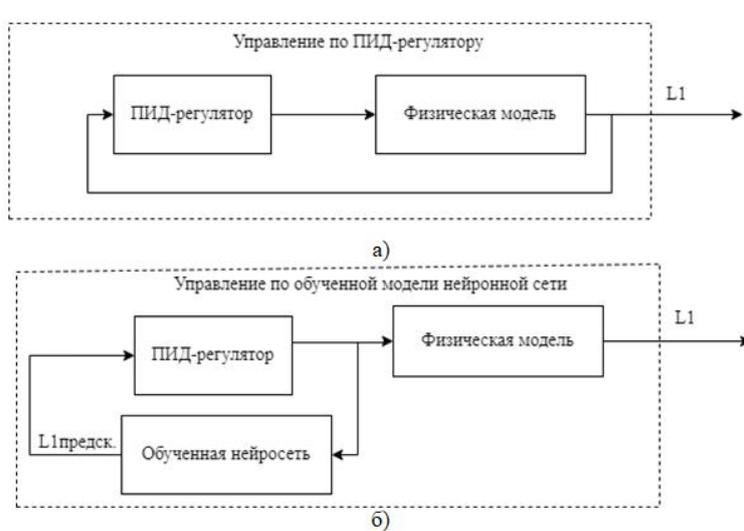


Рис. 5. Структурные схемы для проверки моделей (а – управление по математической модели, б – управление по обученной модели)

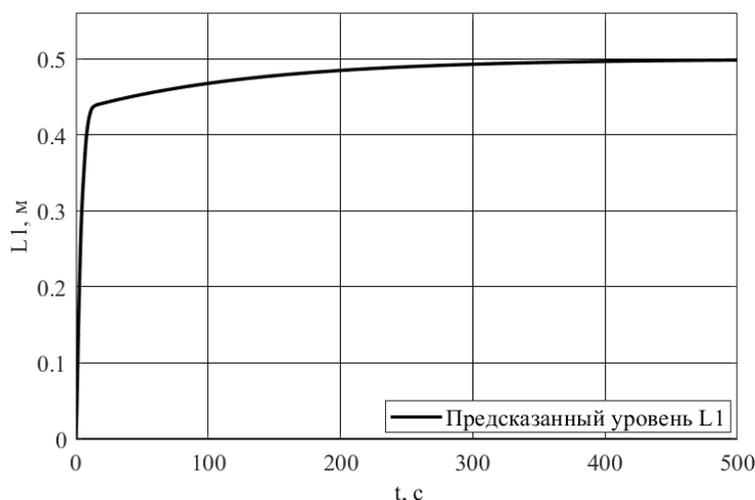


Рис. 6. Предсказанный уровень в первом сосуде

Из переходной характеристики предсказанного уровня, видно, что система управления позволяет стабилизировать уровень воды, предсказанный нейронной сетью, при указании дополнительных параметров Q , k_1 , k_2 , k_2 . Однако при подачи данного управляющего воздействия на математическую модель (структура представлена на рисунке 5) уровень воды значительно отличается от управления по обратной связи с математической модели.

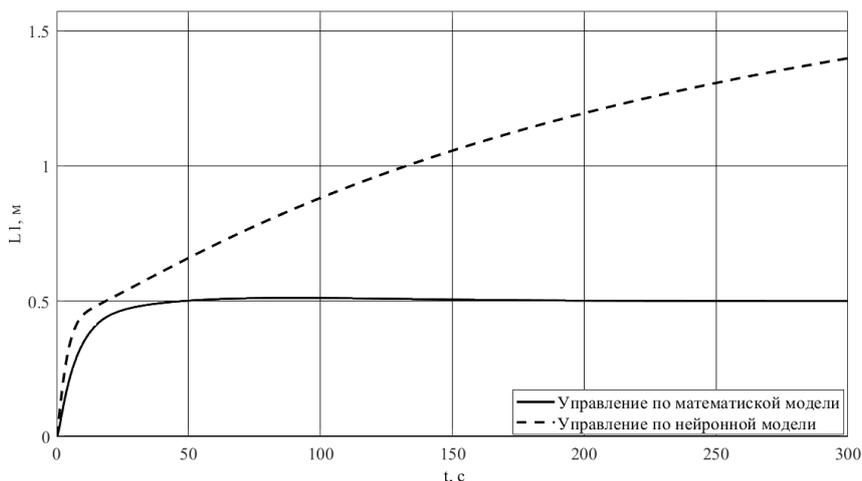


Рис. 7. Сравнения различных управлений

Анализируя график 7, был сделан вывод, что основное рассогласование происходит в статическом режиме, то есть, когда уровень воды доходит до установившегося режима (в данном случае 0.5) формируется управляющее воздействие, которое приводит к постоянному росту воды в резервуаре. При условии, что коэффициенты в сравниваемых системах одинаковые, был сделан вывод, что выход ПИД-регулятора создает такое управляющее воздействие, которое постоянно добавляет в сосуд избыточное количество жидкости, то есть в статическом режиме работы количество жидкости необходимое для поддержания уровня воды в резервуаре нейронная сеть воспринимает с ошибкой. При этом данное явление, существенно не проявляется на графиках обучения моделей (рис 4.а), что еще больше затрудняет решение данной проблемы. При этом работа моделей в динамики, различается не настолько значительно.

Заключение

В работе была построена математическая модель стенда с 2-мя сообщающимися сосудами в виде дифференциальных уравнений, и на ее базе составлена модель в среде Matlab Simulink. Синтезирована система управления уровнем воды в первом резервуаре, подтвердившей правильность работы принципа сообщающихся сосудов, а именно уровень воды во втором резервуаре также

стабилизировался без активного регулирования. На основе данных, полученных с модели с применением методов машинного обучения, были построены модели на основе нейронных сетей. Проведено исследование работы системы на базе ПИД- регулятора с обратной связью с разработанной нейросетевой модели. Выявлена значительная проблема в статическом режиме работы модели, а именно количество жидкости необходимое для поддержания уровня воды в резервуаре для нейросетевой и математической модели значительно отличаются, что приводит к накоплению большой ошибки. Вопрос решения данной проблемы будет рассмотрен авторами в следующих работах.

Список использованных источников

1. Колодин А.А., Мельник С.А. Управление на основе прогнозирующей модели (model predictive control) // Переработка природного и техногенного сырья: сборник научных трудов студентов, магистрантов, аспирантов и молодых ученых Института высоких технологий. – Иркутск: Изд-во ИРННТУ, 2018. – С. 9–14.
2. Леонов А.В. Возможность применения MPC для управления доменной печью // Международная научно-практическая конференция «Научные исследования: теория, методика и практика». – Челябинск: ФГАОУ ВО «Южно-Уральский государственный университет (НИУ), 2017. – С. 38-40.
3. Хасанов Д.С. Мультиагентное моделирование при прогнозировании управления транспортными сетями: статья. – Санкт-Петербург: Российская академия наук. Санкт-Петербургский Федеральный исследовательский центр, 2022. – С 7.
4. Kittisupakorn P., Thitiyasook P., Hussain M.A., Daosud W. Neural network-based model predictive control for a steel pickling process // Journal Process Control. – 2009. – pp. 579-590.
5. А.В. Цавнин, А.Ю. Зарницын, С.В. Ефимов, И.А. Подковыров, С.В. Замятин Метод синтеза регулятора робастного по перерегулированию для АСУ ТП с параметрической неопределенностью // АСУ для промышленных предприятий: Томск, 2021. – С. 2-7.
6. Антонюк Э.А., Голованов А.А., Макаренко В.Г. Математическая модель системы сообщающихся емкостей как объекта управления: Новочеркасск, Южно-Российский Государственный Технический Университет (Новочеркасский Политехнический Институт), 2014. – С. 1-4.