

ПОСТРОЕНИЕ ПРЕДСКАЗАТЕЛЬНОЙ МОДЕЛИ АЭРОДИНАМИЧЕСКОГО СТЕНДА НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Тоневицкая А.К.¹, Беляев А.С.²

¹ *Томский политехнический университет, Инженерная школа информационных технологий и робототехники 8Т12, e-mail: akt13@tpu.ru*

² *Томский политехнический университет, Инженерная школа информационных технологий и робототехники, к.т.н., e-mail: asb22@tpu.ru*

Аннотация

В статье рассмотрен процесс создания модели для объекта с параметрическими неопределенностями с использованием методов машинного обучения, а также разработка системы управления на основе полученной модели. Работа фокусируется на анализе применения современных методик моделирования и управления с целью улучшения эффективности и точности в управлении системами с параметрическими неопределенностями.

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

Введение

Современное производство постепенно начинает переходить от автоматизации отдельных установок к комплексной автоматизации предприятий [1]. В этом контексте задачи управления усложняются. В большинстве случаев управление уже не может базироваться только на единичной обратной связи, как при автоматизации отдельных устройств, в следствии чего используются многоконтурные системы управления, в том числе подчиненного, согласованного или других типов регулирования [2, 3]. Однако, в виду того, что каждый контур управления зависит от вложенных в него контуров, настройка таких систем сложна. Поэтому для настройки такой системы управления на производстве чаще всего используют предварительно построенные математические модели объектов. Альтернативой многоконтурным регуляторам, базирующихся, например на ПИД-регуляторе, являются современные методы управления, основанные на оптимальных и адаптивных методах управления [4]. Среди них можно отметить линейно-квадратичный регулятор (LQR) и MPC регулятор [5, 6]. Достоинства данных методов заключаются в том, что настройка таких регуляторов осуществляется на основе функций систем, зависящих от всех изменяемых параметров внутри системы, в то время как в классическом подчиненном регулировании корректировка этих параметров производится в виде отдельных контуров. В результате в современных методах управления имеется возможность не только согласованной настройки между отдельными параметрами, но и учет корреляционных признаков при переходах из одного состояния системы в другое.

Все указанные методы, в том числе и методы классического многоконтурного управления основываются на применении математических моделей, описывающих сложные динамические процессы. Для описания этих процессов традиционно используются дифференциальные уравнения, базирующиеся на физических законах в той или иной научной области. При этом для составления математических моделей необходимо полное понимание всех задействованных в системе процессов. Альтернативой математическим моделям, построенных на дифференциальных уравнениях, являются модели, строящиеся на основе анализа данных: регрессионный анализ, базисное разложение, экспертные системы, и на основе элементов искусственного интеллекта: нечеткая логика, нейронные сети, генетические алгоритмы и другие. Данные методы по своей сути являются противоположными классическим методам, так как они базируются не на реальных физических законах, а выявляют исключительно математическую зависимость между входными и выходными величинами. При этом достоинство данных моделей заключается в том, что в процессе построения таких моделей происходит учет множества дополнительных факторов, поскольку используемые данные снимаются с реальных объектов и установок. В результате получаемая модель является подходящей для систем с различными неопределенностями, возмущающими воздействиями, которые сложно описать физическими законами и нелинейных систем [7]. Целью данной работы является исследование процесса построения модели объекта с параметрическими неопределенностями с применением алгоритмов машинного обучения и синтеза системы управления на основе полученных моделей.

В данной работе будет рассмотрен метод построения модели регрессии нейронных сетей на основе данных, взятых с модели аэродинамического стенда, имеющей параметрические неопределенности.

Описание стенда и построение структурной схемы

Для построения модели рассмотрим устройство стенда и физические законы, по которым происходит движение шарика в аэротрубе. Стенд состоит из аэродинамической трубы с изменяемым углом наклона, асинхронного двигателя, создающего воздушный поток, направление которого совпадает с направлением трубы. В качестве объекта управления выступает шарик (рис. 1).

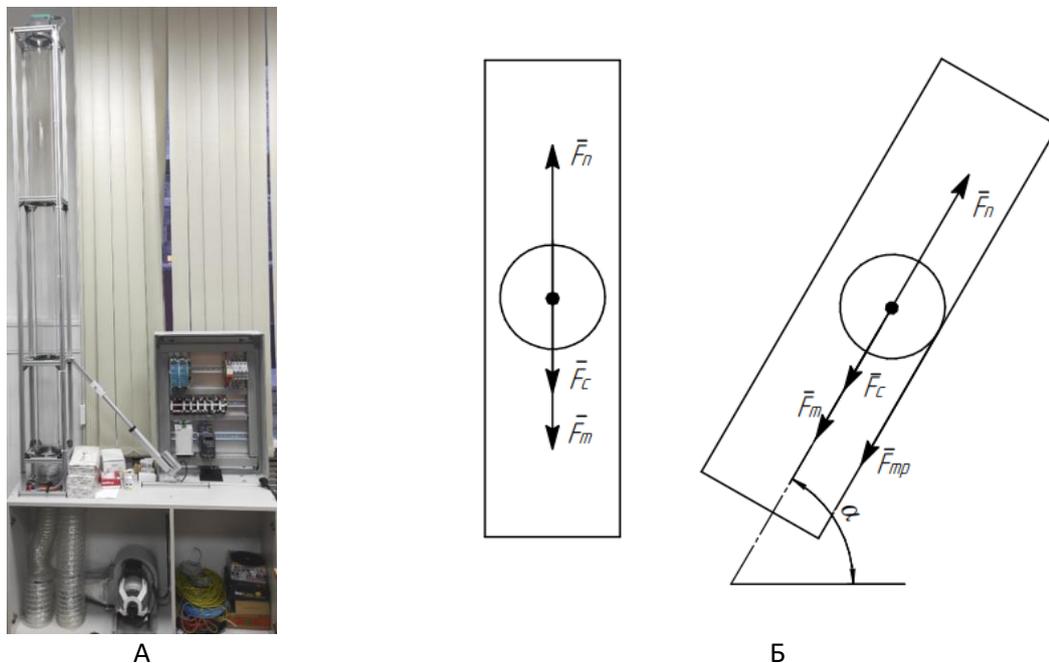


Рис. 1. А) внешний вид стенда; Б) схема стенда с учетом действующих на тело сил

Для моделирования системы необходимо рассмотреть изменение положения объекта в трубе под действием воздушного потока.

Согласно второму закону Ньютона:

$$m\vec{a} = \vec{F}_n + \vec{F}_c + \vec{F}_m + \vec{F}_{mp}, \text{ где } \vec{F}_n - \text{подъемная сила, } \vec{F}_c - \text{сила сопротивления воздуха,}$$

\vec{F}_m – сила тяжести, действующая на объект, \vec{F}_{mp} – сила трения скольжения, которая появляется при наклоне аэротрубы.

$\vec{F}_c = -\zeta(v - \chi \cdot \omega_v)^2$, где ζ – аэродинамический коэффициент, v – скорость объекта в трубе относительно трубы, ω_v – скорость потока воздуха, χ – коэффициент пропорциональности между скоростью вращения турбины и движением воздушного потока.

$$\vec{F}_n = \omega \cdot k_g, \text{ где } \omega - \text{скорость вращения турбины, } k_g - \text{коэффициент подъемной силы.}$$

$$\vec{F}_m = -mg \cdot \sin \alpha, \text{ где } \alpha - \text{угол наклона трубы.}$$

$$\vec{F}_{mp} = -\mu \cdot mg \cdot \cos \alpha, \text{ где } \mu - \text{коэффициент трения скольжения резина-стекло.}$$

Так же отметим, что ускорение является второй производной координаты по времени:

$$\vec{a} = \ddot{h}, \text{ а скорость объекта в трубе относительно трубы – производная координаты по времени: } v = \dot{h}$$

Подставив все переменные получим следующее дифференциальное уравнение, описывающее систему:

$$m\ddot{h} = \omega \cdot k_g - \zeta(\dot{h} - \chi \cdot \omega_v)^2 - mg \cdot \sin \alpha - \mu \cdot mg \cdot \cos \alpha$$

В качестве двигателя используем функцию $W = \frac{0,03}{s + 20,02}$. Коэффициенты $\chi = 4$, $\zeta = 0,02$,

$k_b = 100$. Коэффициенты для функции были взяты из научно-исследовательской работы [8], угол $\alpha = \frac{\pi}{4}$, $\mu = 0,5$.

Система в качестве входного воздействия получает желаемое значение положения шарика в трубе, что достигается использованием контура управления на базе ПИД-регулятора, который регулирует положение шарика. Для подбора коэффициентов ПИД-регулятора. Настройка коэффициентов регулятора осуществлялась с использованием встроенных средств PID Tuner.

На рис. 2 изображена схема, построенная на основе дифференциальных уравнений в MATLAB Simulink.

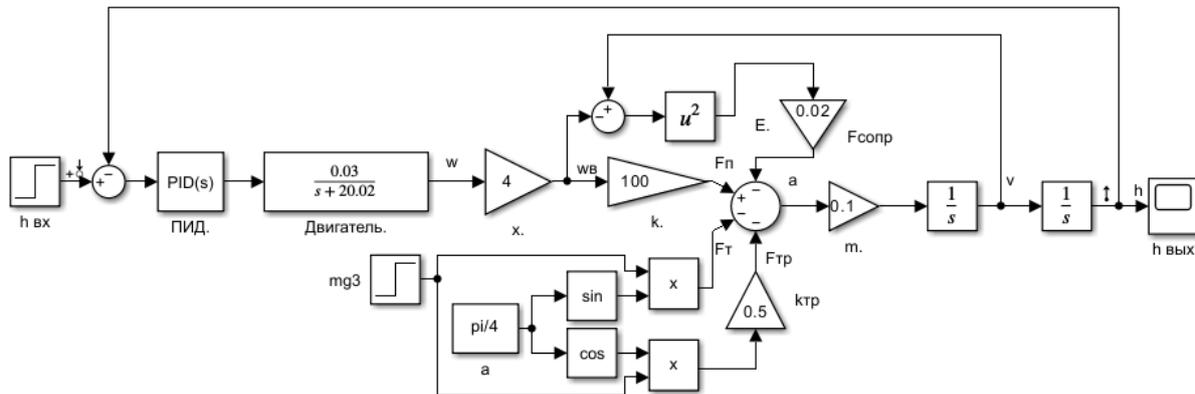


Рис. 2. Схема системы в MATLAB Simulink

Процесс работы системы стабилизации положения объекта в трубе с помощью ПИД-регулятора приведен на рисунке 3.

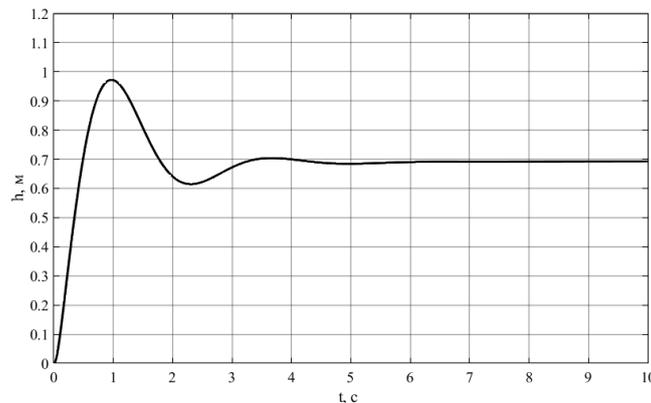


Рис. 3. Переходный процесс установления желаемого положения шарика

Для построения модели прогнозирования изменения положения шарика были собраны данные с системы с ПИД-регулятором с помощью блока to workspace. Исследовалось изменение положения шарика при различных значениях угла наклона аэродинамической трубы α . Были построены модели прогнозирования для двух случаев:

1. Угол α неизменен и равен $\frac{\pi}{4}$.
2. Угол α варьируется от $\frac{\pi}{4}$ до $\frac{3\pi}{4}$ с шагом $\frac{\pi}{36}$.

На вход системы подавали значения угла наклона α , скорость вращения турбины двигателя ω_b , в текущий и предыдущий момент времени, на выходе системы отслеживались значения ускорения шарика \ddot{h} .

Обучение моделей

Для построения модели, которая позволит предсказывать ускорения шарика при переменных параметрах, воспользуемся приложением машинного обучения Regression Learner. Выбрав описанные выше величины в качестве входных величин (Predictors), от которых зависит значение выходной величины (Response), построим модель по методу кросс-валидации [9]. Исходя из значений среднеквадратических отклонений была выбрана наиболее точная модель – модель регрессии широкой нейронной сети (Wide Neural Network). Wide Neural Network представляет собой полностью связанную нейронную сеть прямого распространения с большим количеством нейронов в скрытых слоях. Это позволяет сети захватывать более сложные отношения в данных. Значения среднеквадратических ошибок для полученных моделей были равны 0,004808 и 0,00107 для постоянного и изменяемого угла наклона трубы соответственно. На рисунке 4 изображены графики полученных моделей, желтыми точками обозначены предсказанные моделью данные, а синими – данные, снятые с системы.

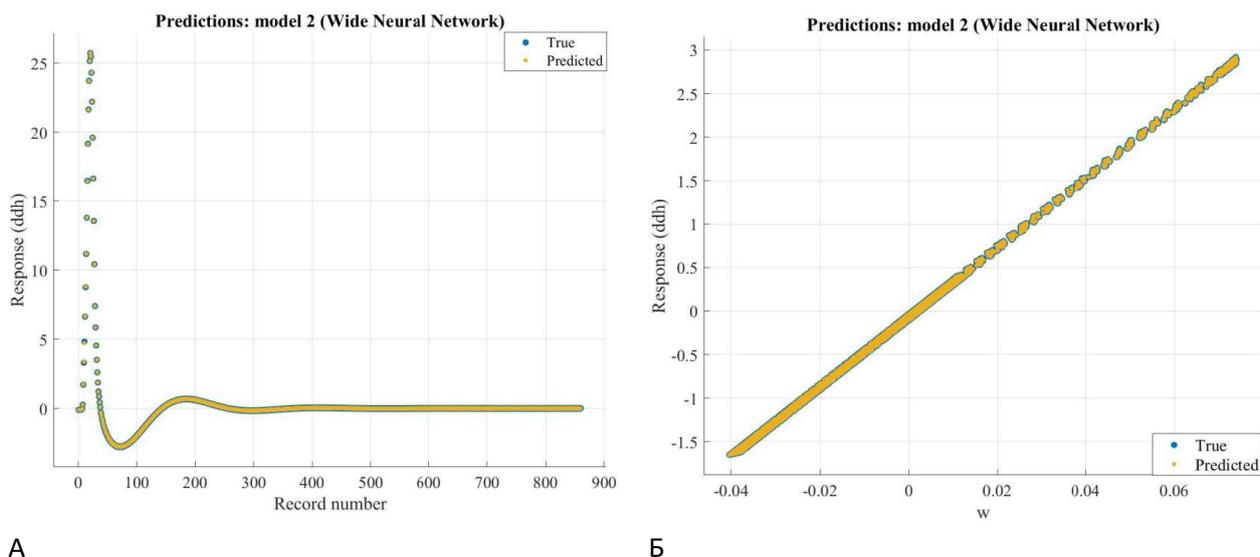


Рис. 4. Значения ускорения шарика от времени при постоянном α (А) и скорости вращения турбины w , при изменяющемся α (Б)

При запуске модели, шарик обретает значительное ускорение, которое в дальнейшем уменьшается и с приближением шарика к заданному уровню, становится практически нулевым. Так же можно наблюдать линейную зависимость ускорения шарика от скорости вращения двигателя.

Следующим шагом станет проверка адекватности полученной модели в контуре системы управления. Для этого воспользуемся блоком Regression Neural Network Predict, на выходе этого блока получим ускорение шарика, проинтегрировав которое, можем получить значение положения шарика в трубе. Эти значения, подадим в обратную связь, обеспечив тем самым управление по отклонению. Схема управления системой по обученной модели регрессии показана на рисунке 5.

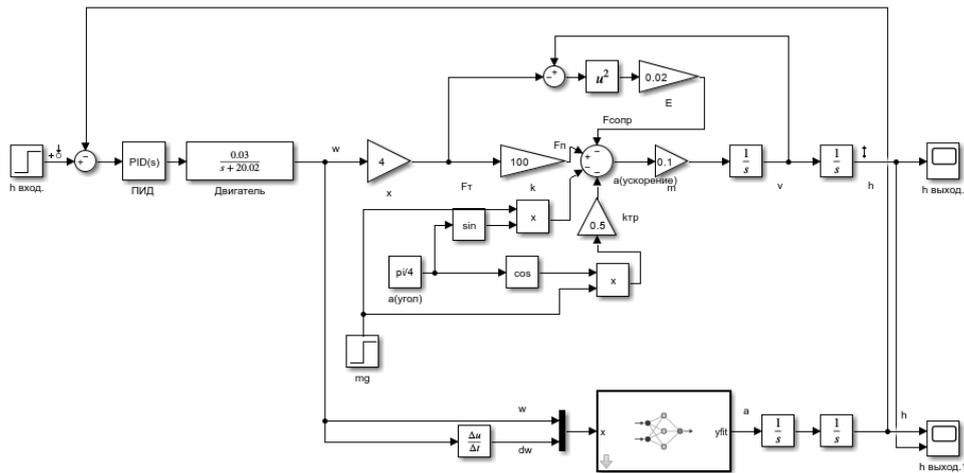


Рис. 5. Система управления с помощью регрессионной модели

На рисунке 6 изображена зависимость положения шарика от времени при регулировании с помощью модели регрессии нейронных сетей для случая с изменяемым углом наклона.

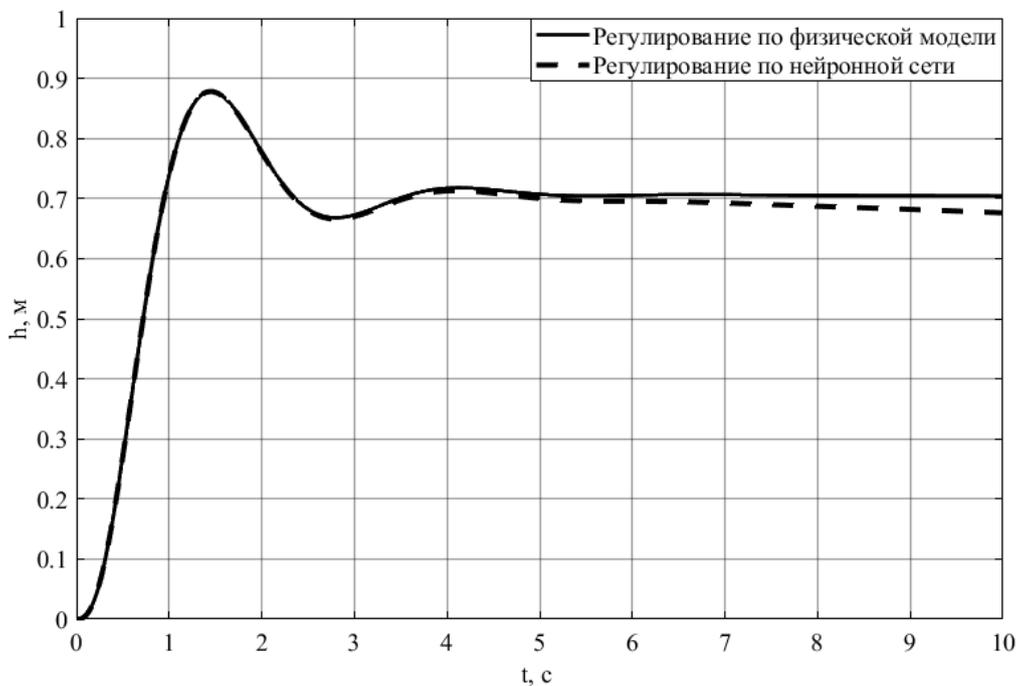


Рис. 6. Система управления с помощью регрессионной модели

С увеличением времени, наблюдается увеличение статической ошибки, это происходит из-за включения в регулирование системы интеграторов, которые накапливают в себе небольшие отклонения в статическом режиме работы. Так же можно отметить достаточно точное регулирование системы в динамическом режиме, при использовании модели регрессии нейронных сетей, что подтверждает столь малые значения среднеквадратических отклонений ошибок и адекватность полученных моделей.

Заключение

В работе была построена математическая модель аэродинамического стенда на основе дифференциальных уравнений и на ее базе составлена модель в среде Matlab Simulink. Синтезирована система управления желаемым значением положения шарика в аэротрубе при помощи ПИД-регулятора с обратной связью. На основе данных, полученных с модели, с помощью методов

машинного обучения были построены регрессионные модели на базе нейронных сетей. Осуществлено управление системой при включении в обратную связь выходных данных с нейросетевой модели. Внедрение полученной модели показало хорошее качество регулирования системой на динамическом участке процесса, однако при статическом режиме работы, при необходимом небольшом изменении положения шарика появляется статическая ошибка, которая обусловлена необходимостью интегрирования выходной величины с модели для введения в обратную связь нужного параметра – положения шарика. Решением данной проблемы может послужить добавление фильтра на выходе нейросетевой модели, что позволит сгладить малые колебания выходного параметра.

Список использованных источников

1. Mohsen S., Behrooz A., Roza D. Internet of things for smart factories in industry 4.0, a review // *Internet of Things and Cyber-Physical Systems*. – 2023.
2. Плешивцева Ю.Э., Афиногентов А.А. Альтернативный метод структурно-параметрического синтеза каскадных систем автоматического управления // *Статья в журнале Автометрия*. – 2015. – С. 17–26.
3. Солонников Ю.Я., Иванов В.Э. Реализация адаптивного нечеткого пид-регулятора для системы управления подчиненного регулирования двухконтурного электропривода постоянного тока // *Информационные технологии XXI века сборник научных трудов. Хабаровск, 2017*. – С. 100–110.
4. Zheltukhina J.A., Kuskashov P.N. Application of fuzzy logic and artificial neural networks in pid controllers // *статья в журнале: Молодежь. общество. современная наука, техника и инновации - материалы конференции*. – 2022. – № 21. – С. 81–82.
5. Schwenzer, M., Ay, M., Bergs, T. Review on model predictive control: an engineering perspective // *The International Journal of Advanced Manufacturing Technology*. – 2021. – Pg. 1327-1349.
6. Бушко Д.А., Пашин С.С. Синтез MPC регулятора с использованием линейной модели судна // *Вестник морского государственного университета*. – 2015. – № 68. – С. 6-10.
7. Косырев Е.А., Лутаев Д.О., Солодов А.Г. Введение в машинное обучение и искусственный интеллект // *Актуальные вопросы развития естественных и технических наук. Материалы XXX Всероссийской научно-практической конференции. Ставрополь*. – 2023. – С 37-40.
8. Усенко К.Ю., Тырышкин А.В. Отчет по научно-исследовательской работе студента ОАР ИШИТР ТПУ
9. Kucheryavskiy S., Rodionova O., Pomerantsev A. Procrustes cross-validation of multivariate regression models // *Analytica Chimica Acta*. – 22 March 2023.