

17. Kurochkin A.G., Titenko E.A. Modifitsirovannyu algoritm sglazhivaniya toчек маршрута [Modified algorithm for smoothing route points], *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* [Izvestiya of the Southwest State University], 2016, No. 5 (68), pp. 43-51.
18. Shmal'ko E.Yu., Rummyantsev Yu.A., Baynazarov R.R., Yamshanov K.L. Identifikatsiya neyrosetevoy modeli robota dlya resheniya zadachi optimal'nogo upravleniya [Identification of a neural network model of a robot for solving optimal control problems], *Informatika i avtomatizatsiya* [Informatics and Automation], 2021, Vol. 20, No. 6, pp. 1254-1278. DOI 10.15622/ia.20.6.3.
19. Kenzin M.Yu., Bychkov I.V., Maksimkin N.N. Kompleksnyu mnogotsel'noy monitoring gruppy avtonomnykh transportnykh sredstv [Integrated multi-purpose monitoring by a group of autonomous vehicles], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2019, No. 7 (209), pp. 82-92. DOI 10.23683/2311-3103-2019-7-82-92.
20. Kazakov K.A., Semenov V.A. Obzor sovremennykh metodov planirovaniya puti [Review of modern path planning methods], *Tr. ISP RAN* [Proceedings of ISP RAS], 2016, Vol. 28, No. 4, pp. 241-294.

Данильченко Владислав Иванович – Южный федеральный университет; e-mail: vdanielchenko@sfedu.ru; г. Таганрог, Россия, тел.: 88634371651; кафедра систем автоматизированного проектирования им. В.М. Курейчика; доцент.

Бова Виктория Викторовна – Южный федеральный университет; e-mail: vbova@sfedu.ru; г. Таганрог, Россия, тел.: 88634371651; кафедра систем автоматизированного проектирования им. В.М. Курейчика; доцент.

Danilchenko Vladislav Ivanovich – Southern Federal University; e-mail: vdanielchenko@sfedu.ru; Taganrog, Russia; phone: +78634371651; V.M. Kureichik Computer-Aided Design Systems Department; associate professor.

Bova Victoria Viktorovna – Southern Federal University; e-mail: vbova@sfedu.ru; Taganrog, Russia; phone: +78634371651; V.M. Kureichik Computer-Aided Design Systems Department; associate professor.

УДК 519.711

DOI 10.18522/2311-3103-2025-6-276-287

Б.А. Комаров, С.В. Леонов, Т.Е. Мамонова

НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ МОДЕЛЬНО-ПРОГНОЗИРУЮЩЕГО УПРАВЛЕНИЯ ДЛЯ СИСТЕМЫ СТАБИЛИЗАЦИИ ДИНАМИЧЕСКОГО ОБЪЕКТА

Актуальность. При решении задач стабилизации динамических объектов достаточно широко применяется классическое модельно-прогнозирующее управление. Оно обеспечивает высокое качество управления за счёт решения задачи оптимизации на каждом шаге, однако обладает значительными вычислительными затратами, что ограничивает его применение в системах реального времени с высокими требованиями к частоте обновления. Поэтому вопрос исследования применимости нейросетевого регулятора, обученного на модельно-прогнозирующем регуляторе (МРС) при решении задачи стабилизации положения динамического объекта при ограниченном вычислительном и временном ресурсе является актуальной. **Цель.** Целью представленной работы было разработать и исследовать нейросетевой регулятор, обученный на основе МРС-регулятора, для стабилизации положения динамического объекта на подвижной платформе. **Методы.** При выполнении работы использовались методы системного анализа, имитационного моделирования, а также экспериментальные испытания на стенде. **Результаты и выводы.** В рамках исследования разработан и обучен нейросетевой регулятор, аппроксимирующий поведение МРС на основе данных, полученных при управлении реальной балансировочной платформой. Обучение проводилось по входным и выходным данным МРС без использования внутренней модели системы, что позволило воспроизвести динамику регулятора при существенно меньших вычислительных затратах. Экспериментальные результаты показали, что нейросетевая модель обеспечивает качество стабилизации, сопоставимое с оригинальным МРС, при этом время вычислений сократилось с 47 мс до 1.6 мс, что составило значение ускорения в 29 раз. Предложенный подход демонстрирует потенциал нейросетевых методов управления в задачах замещения сложных оптимизационных регуляторов для систем с ограниченными вычислительными ресурсами.

Нейросетевой регулятор; модельно-прогнозирующее управление (МРС); стабилизация положения; балансировочная платформа; аппроксимация МРС; оптимизация управления.

B.A. Komarov, S.V. Leonov, T.E. Mamonova

NEURAL NETWORK APPROXIMATION OF MODEL-PREDICTIVE CONTROL FOR A DYNAMIC OBJECT STABILIZATION SYSTEM

Relevance. When solving problems of stabilization of dynamic objects, classical model predictive control is widely used. It provides high quality control by solving the optimization problem at each step, but it has significant computing costs, which limits its application in real-time systems with high requirements for update frequency. Therefore, the question of investigating the applicability of a neural network regulator trained on a model predictive regulator (MPC) when solving the problem of stabilizing the position of a dynamic object with a limited computational and time resource is relevant. **Goal.** The purpose of the presented work was to develop and study a neural network regulator trained on the basis of an MPC regulator to stabilize the position of a dynamic object on a mobile platform. **Methods.** When performing the work, methods of system analysis, simulation modeling, as well as experimental tests on the bench were used. **Results and conclusions.** As part of the study, a neural network regulator was developed and trained that approximates the behavior of MPC based on data obtained when controlling a real balancing platform. The training was conducted on the input and output data of the MPC without using the internal model of the system, which made it possible to reproduce the dynamics of the regulator at significantly lower computational costs. Experimental results showed that the neural network model provides a stabilization quality comparable to the original MPC, while the calculation time was reduced from 47 ms to 1.6 ms, which amounted to an acceleration value of 29 times. The proposed approach demonstrates the potential of neural network control methods in the problems of replacing complex optimization regulators for systems with limited computing resources.

Neural network regulator; model predictive control (MPC); position stabilization; balancing platform; MPC approximation; management optimization.

Введение. В настоящее время проблема стабилизации динамических объектов является одной из самых важных при проектировании и эксплуатации технических устройств специального назначения, работающих в неопределенных заранее условиях с ограничением временных и вычислительных ресурсов [1–3].

Модельно-прогнозирующее управление (МРС) является одним из наиболее эффективных подходов современной теории управления, позволяющим учитывать ограничения на управление и прогнозировать поведение системы на горизонте предсказания [4–8]. Тем не менее, основным недостатком МРС заключается в высокой вычислительной сложности: на каждом шаге требуется решать задачу оптимизации, что приводит к значительным временным затратам. Это ограничивает применение МРС в системах реального времени, особенно для объектов с высокой частотой дискретизации [9].

Для снижения вычислительных затрат активно исследуются подходы, основанные на замещении МРС-регулятора нейросетевыми моделями [10–17]. В таких работах нейросеть обучается воспроизводить поведение МРС, фактически заменяя процесс онлайн-оптимизации на прямой вызов аппроксиматора. Подобные методы демонстрируют ускорение в десятки раз при минимальной потере качества управления. Однако большинство исследований проводилось на симулированных данных и для упрощенных моделей систем. Реальное применение таких регуляторов на физических установках остаётся ограниченным.

Настоящая работа посвящена исследованию применения нейросетевого аппроксиматора МРС в задаче стабилизации шарика на подвижной платформе – классической линейной системы с элементами стохастического поведения. В отличие от большинства известных исследований, обучение нейросети проводилось на экспериментальном стенде и его реальной модели, с использованием только входных и выходных данных МРС-регулятора без доступа к внутренним параметрам модели.

Целью представленной работы было разработать и исследовать нейросетевый регулятор, обученный на основе МРС-регулятора, для стабилизации положения динамического объекта на подвижной платформе.

Основные задачи работы:

- 1) разработка и реализация МРС-регулятора для реальной балансировочной платформе;
- 2) обучение нейросети- на основе данных, собранных с физического стенда;
- 3) экспериментальное сравнение качества регулирования.

Для оценки результатов работы исследуемых регуляторов использован классический ПИД-регулятор, вычисляющий управляющее воздействие как комбинацию пропорциональной, интегральной и дифференциальной составляющих ошибки:

$$u(t) = K_p e(t) + K_i \int e(t) dt + K_d \frac{de(t)}{dt} + u_{\text{bias}},$$

где $e(t) = r(t) - y(t)$ – ошибка между уставкой и текущим значением выхода системы, K_p, K_i, K_d – коэффициенты регулятора, а u_{bias} – смещение. Для уменьшения влияния шума применялось экспоненциальное сглаживание текущего значения. Управляющее воздействие ограничивалось в пределах допустимого диапазона привода.

Описание экспериментального стенда и методика испытаний.

Экспериментальный стенд на рис. 1 включает сервопривод, на оси которого закреплена балка квадратного сечения. По поверхности балки свободно перемещается динамический объект – шарик. Положение шарика в реальном времени фиксируется видеокamerой, установленной сверху. Сигнал с камеры обрабатывается компьютером, который формирует управляющее воздействие для сервопривода, замыкая контур управления.



Рис. 1. Экспериментальная установка

Математическая модель объекта управления описана с учётом силы тяжести F_T , силы реакции опоры N , силы трения качения $F_{\text{тр}}$, и момента инерции I . Ускорение шара определяется как:

$$a = \frac{5}{7} \cdot g \cdot \sin(\theta),$$

где g – ускорение свободного падения, м/с^2 ; θ – угол наклона поверхности, град; a – ускорение шара, м/с^2 .

Динамика сервопривода аппроксимирована апериодическим звеном первого порядка:

$$W(s) = \frac{K}{T \cdot s + 1},$$

где K – коэффициент передачи; T – постоянная времени.

Таким образом, результирующая передаточная функция для нахождения координат шара:

$$W(s) = \frac{K_{\text{рез}}}{s^2 \cdot (T \cdot s + 1)},$$

где $K_{\text{рез}}$ – результирующий коэффициент передачи, равный:

$$K_{\text{рез}} = K \cdot \frac{5}{7} \cdot g \cdot \sin(\theta),$$

Параметры модели ($K_{\text{рез}} = 0.79$, $T = 0.22$) были идентифицированы с использованием метода наименьших квадратов по экспериментальным данным.

В уравнениях состояния в дискретной форме с шагом дискретизации 0.1 с модель объекта системы имеет вид:

$$x_{k+1} = \begin{bmatrix} 1 & 0.1 & 0 \\ 0 & 1 & -0.079 \\ 0 & 0 & 0.5455 \end{bmatrix} \cdot x_k + \begin{bmatrix} 0 \\ 0 \\ 0.4545 \end{bmatrix} \cdot u_k$$

$$y_k = [1 \ 0 \ 0] \cdot x_k$$

Для оценки эффективности регуляторов проводилось тестирование в идентичных условиях. В систему подавались одинаковые ступенчатые сигналы уставки с фиксированной амплитудой и длительностью. Управляющие алгоритмы работали в режиме стабилизации, т.е. задача заключалась в перемещении и удержании шарика вблизи заданной координаты при изменении уставки. Исследуемые системы с тремя типами регуляторов (ПИД, модельно-прогнозирующий и нейросетевой) настроены на показатели качества, удовлетворяющие условиям: перерегулирование σ – не более 5 %; время переходного процесса h_{st} – не более 3 с; статическая ошибка ε – не более 5 мм.

На первом шаге для сравнительного анализа эффективности алгоритмов управления были получены переходные характеристики системы с ПИД-регулятором. На рис. 2 проиллюстрированы графики координаты шара от времени, которые наглядно демонстрируют разницу в качестве управления.

ПИД-регулятор на рис. 2 обеспечивает колебательный переходный процесс с значительным перерегулированием. Система длительное время не может выйти на установившийся режим, что свидетельствует о недостаточной демпфирующей способности этого способа управления динамическим объектом. Параметры ПИД-регулятора: пропорциональная составляющая $K_p = 4$; интегральная составляющая $K_i = 0.001$; дифференциальная составляющая $K_d = 4$.

На рис. 3 приведен график изменения угла оси электропривода, отражающий характер управляющих сигналов, вырабатываемых ПИД-регулятором.

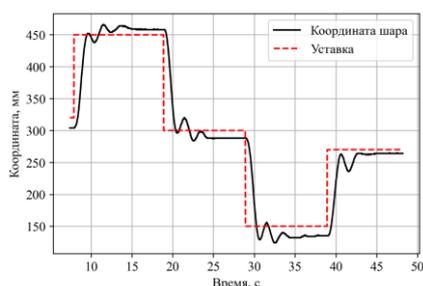


Рис. 2. Переходная характеристика системы с ПИД-регулятором

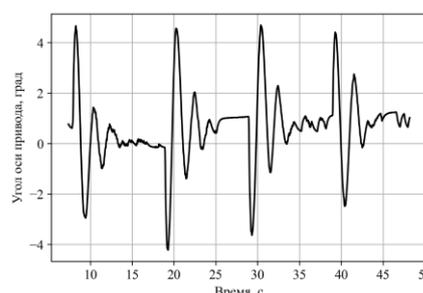


Рис. 3. Угол привода при управлении ПИД-регулятором

Для ПИД-регулятора характерно реактивное управление, при котором резкие изменения угла положения возникают как запоздавшая реакция на отклонение шарика. Это приводит к «перелётам» через положение уставки и последующим колебаниям системы по управлению.

Алгоритм модельно-прогнозирующего управления с учётом задержки и расширенных состояний. Принцип MPC регулирования заключается в том, что на каждом шаге дискретного времени формируется оптимальная последовательность управляющих воздействий, минимизирующая функцию стоимости при учёте ограничений на состояние и управление. На объект подаётся только первое управление из найденной последовательности, после чего процесс повторяется с обновлённым состоянием системы [18].

В общем случае динамика объекта описывается линейной дискретной моделью:

$$x_{k+1} = Ax_k + Bu_k, y_k = Cx_k,$$

где $x_k \in \mathbb{R}^n$ – вектор состояния; $u_k \in \mathbb{R}^m$ – управляющее воздействие; $y_k \in \mathbb{R}^p$ – выход системы; A, B, C – матрицы состояния, управления и выхода соответственно.

На каждом шаге времени k прогнозируется поведение системы на горизонте N шагов вперёд:

$$\hat{x}_{k+i+1|k} = A\hat{x}_{k+i|k} + Bu_{k+i|k}, i = 0, 1, \dots, N - 1,$$

В классическом MPC цель управления формулируется через функцию стоимости, минимизация которой определяет оптимальную последовательность управляющих воздействий на горизонте предсказания. Функция стоимости отражает компромисс между точностью слежения за заданной траекторией и величиной управляющих воздействий.

Для линейной дискретной системы в пространстве состояний функция стоимости на горизонте N записывается в виде квадратичного функционала:

$$J(\mathbf{U}; x_k) = \sum_{i=0}^{N-1} [(\hat{x}_{k+i|k} - r_{k+i})^T Q(\hat{x}_{k+i|k} - r_{k+i}) + u_{k+i|k}^T R u_{k+i|k}]$$

где $\hat{x}_{k+i|k}$ – прогноз состояния на шаге $k + i$, сделанный в момент времени k ; r_{k+i} – опорная траектория для состояния; $u_{k+i|k}$ – прогнозируемое управляющее воздействие; Q – весовая матрица для отклонений состояния (определяет, насколько важно минимизировать отклонение каждого состояния от заданной траектории); R – весовая матрица для управляющих воздействий (штрафует величину управляющих воздействий, позволяя настроить характер управления) [19–20].

Таким образом, функция стоимости выполняет несколько взаимосвязанных задач. Во-первых, она непосредственно измеряет отклонение прогнозируемого состояния системы от заданной опорной траектории и одновременно учитывает величину управляющих воздействий, что позволяет регулировать компромисс между точностью слежения и усилиями управления. Во-вторых, через весовые матрицы Q и R реализуется гибкая настройка приоритетов: можно сделать акцент на контроле наиболее критичных переменных состояния или, наоборот, ограничить нагрузку на исполнительные механизмы.

В классическом MPC предполагается, что управляющее воздействие подаётся на систему без задержек. Однако в реальных системах часто присутствует аperiodическое запаздывание управления, например, из-за задержки передачи сигнала, ограничений привода или времени реакции исполнительного механизма. Для корректного учёта таких задержек был применён подход с расширенными матрицами состояния и буфером управления, что позволяет включить известные уже поданные воздействия в алгоритм оптимизации.

Если задержка управления составляет d дискретных шагов, то вектор состояния системы можно расширить, включив в него последние d управляющих воздействий:

$$x_k^{aug} = \begin{bmatrix} x_k \\ u_{k-1} \\ u_{k-2} \\ \dots \\ u_{k-d} \end{bmatrix} \in \mathbb{R}^{n+d-m},$$

где $x_k \in \mathbb{R}^n$ – исходное состояние системы, $u_{k-i} \in \mathbb{R}^m$ – уже поданные управления.

Расширенные матрицы системы формулируются так, чтобы в составе линейной дискретной динамики учитывались эти прошлые воздействия:

$$x_{k+1}^{aug} = A_{aug}x_k^{aug} + B_{aug}u_k,$$

Далее на каждом шаге времени прогнозируется поведение расширенной системы на горизонте планирования N шагов вперёд:

$$\hat{x}_{k+i+1|k}^{aug} = A_{aug}\hat{x}_{k+i|k}^{aug} + B_{aug}u_{k+i|k}, i = 0, 1, \dots, N - 1.$$

где

$$A_{aug} = \begin{bmatrix} A & B & 0 & \dots & 0 \\ 0 & 0 & I & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & I \\ 0 & 0 & 0 & \dots & 0 \end{bmatrix}, B_{aug} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ I \end{bmatrix}.$$

Функция стоимости формулируется аналогично классическому MPC-регулятору, но теперь с использованием расширенного состояния:

$$J(\mathbf{U}; x_k^{aug}) = \sum_{i=0}^{N-1} [(\hat{x}_{k+i|k}^{aug} - r_{k+i})^T Q_{aug} (\hat{x}_{k+i|k}^{aug} - r_{k+i}) + u_{k+i|k}^T R u_{k+i|k}],$$

где Q_{aug} – расширенная весовая матрица, включающая приоритеты для состояния системы.

Буфер управления, состоящий из последних d уже поданных воздействий, формирует начальные значения для расширенного состояния x_k^{aug} . Таким образом, первые шаги горизонта не оптимизируются, так как они уже реализованы через буфер, а оптимизация выполняется только по будущим управляющим воздействиям. В итоге, на каждом шаге управления решаются следующие задачи:

- ◆ этап 1 – формируется расширенный вектор состояния:
 $x = [x_k, u_{k-1}, u_{k-2}, \dots, u_{k-d}]^T$;
- ◆ этап 2 – выполняется оптимизация с учётом уже применённых, но ещё не реализованных воздействий;
- ◆ этап 3 – в физическую систему подаётся только первое управляющее воздействие из оптимальной последовательности;
- ◆ этап 4 – буфер MPC-регулятора обновляется добавлением нового управления.

На каждом шаге работы MPC решается задача квадратичной оптимизации [18]:

$$\min_U \sum_{k=0}^{N-d-1} (x_k - r_{k+d})^T Q (x_k - r_{k+d}) + u_k^T R u_k,$$

при условиях:

$$x_{k+1} = Ax_k + Bu_k, x_0 = x_{init}, u_{min} \leq u_k \leq u_{max},$$

где N – горизонт предсказания; Q и R – матрица весов для состояния и управления; r_k – опорная траектория (установка); u_{min} , u_{max} – ограничения на управляющее воздействие [21–25].

Таким образом, MPC с учётом задержки сохраняет преимущества классического предсказательного управления, одновременно корректно учитывая физическую задержку исполнительных механизмов, что повышает точность и стабильность управления. Тем не менее, как и утверждалось ранее – основной недостаток MPC заключается в высокой вычислительной сложности. И, в случае решения задач управления многосвязными динамическими объектами к аппаратной части предъявляются повышенные требования.

Для сравнительного анализа эффективности алгоритмов управления были получены переходные характеристики системы по каналу положения динамического объекта, изображённые на рис. 4.

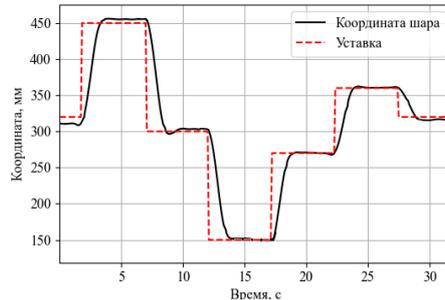


Рис. 4. Переходные характеристики системы с прогнозирующим регулятором

MPC-регулятор на рис. 4 обеспечивает аperiodический переходный процесс с плавным выходом на заданное значение. Отсутствие колебаний указывает на эффективную компенсацию инерционности объекта и запаздываний в системе. Для оценки производи-

тельности регуляторов проведен количественный анализ ключевых метрик, представленный в табл. 1. Данные табл. 1 подтверждают преимущество MPC-регулятора по всем показателям качества. Время переходного процесса сокращено в 2 раза, статическая ошибка уменьшена более чем в 2 раза, при этом перерегулирование полностью устранено.

Таблица 1

Сравнительные показатели качества управления

Показатель качества	ПИД-регулятор	MPC-регулятор
Перерегулирование, %	18.5	0.0
Время переходного процесса, с	3.87	1.95
Статическая ошибка, мм	10.5	4.75

На рис. 5 приведен график изменения угла оси электропривода, отражающий характер управляющих сигналов, вырабатываемых MPC-регулятором. В этом случае система работает упреждающе, на основе прогноза динамики он формирует оптимальные управляющие воздействия до появления значительного рассогласования. В целом, данное управление более точное и направленное, без лишних колебаний и с меньшими затратами энергии.

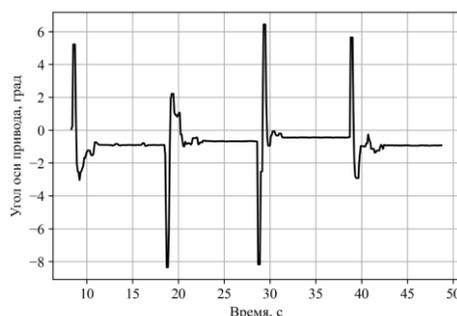


Рис. 5. Угол привода при управлении MPC-регулятором

Проведённое исследование демонстрирует значительное преимущество модельно-прогнозирующего регулятора (MPC) перед классическим ПИД-регулятором в задаче стабилизации линейного объекта с запаздыванием. Количественные результаты подтверждают, что MPC обеспечил апериодический переходный процесс с полным отсутствием перерегулирования, сократил время переходного процесса в 2 раза (с 3.87 с до 1.95 с) и снизил статическую ошибку более чем в 2 раза (с 10.5 мм до 4.75 мм).

Предложенный подход с буфером управляющих воздействий в MPC позволил эффективно компенсировать программные и механические запаздывания, что недостижимо для реактивного ПИД-управления. MPC обеспечивает не только более высокую точность, но и повышает плавное, энергоэффективное управление за счёт упреждающего прогнозирования динамики системы. Результаты работы подтверждают перспективность применения MPC для широкого класса механических систем, требующих точной стабилизации в условиях запаздываний в области робототехники и систем автоматизации. Основным ограничением MPC является его высокая вычислительная сложность и зависимость от точности модели. Перспективы дальнейших исследований видятся в разработке адаптивных версий MPC, оптимизации вычислительных алгоритмов для реализации на embedded-платформах, а также в применении нейросетевых алгоритмов управления.

Далее для аппроксимации поведения модельно-прогнозирующего регулятора была использована нейронная сеть прямого распространения, обучаемая по данным, собранным при работе MPC-регулятора на реальном стенде. Архитектура сети выбрана в соответствии с подходом, представленным в работе [7]. Сеть состоит из 6 скрытых слоёв по 6 нейронов в каждом слое и использует функцию активации для каждого нейрона *ReLU*. Входной вектор включает параметры текущего состояния системы и заданного положения, а выходом является управляющее воздействие, эквивалентное сигналу MPC:

$$u_N = f_{NN}(x, \text{setpoint}, \text{velocity}, \text{angle}),$$

где x – координата динамического объекта; setpoint – уставка; velocity – скорость шара; angle – угол наклона платформы.

Выход сети соответствует предсказанному управляющему сигналу u_k , вычисляемому MPC.

Для обучения были использованы экспериментальные данные, собранные с физического стенда и содержащие следующие характеристики: положение шарика, скорость поворота и угол наклона платформы. Входные данные нормировались с помощью стандартизации (StandardScaler), параметры нормировщиков сохранялись для последующего применения при работе сети в реальном времени. Модель обучена в среде «PyTorch» методом «Supervised Learning» с функцией потерь среднеквадратичной ошибки (MSE) и оптимизатором **Adam** (скорость обучения 0.001, 500 эпох). Для оценки обобщающей способности данные были разделены на обучающую и тестовую выборки в пропорции 80/20. После завершения обучения среднеквадратичная ошибка (MSE) на тестовой выборке составила **0.066**. На рис. 5 приведена модель нейронной сети. График динамики обучения приведен на рис. 6, график сравнения отклика MPC и нейросетевого регулятора приведен на рис. 7. Как видно из графиков отклика, показанных на рис. 7, нейронная сеть с высокой точностью повторяет характер управления MPC регулятора.

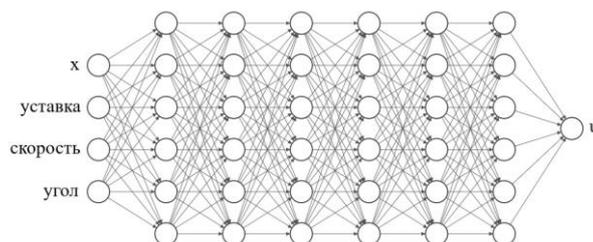


Рис. 5. Модель нейронной сети

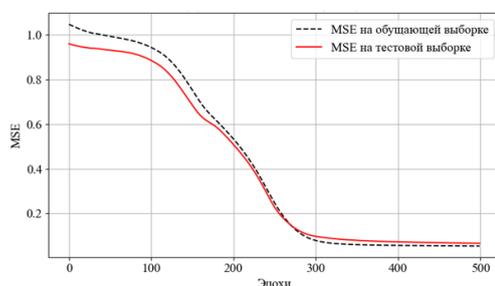


Рис. 6. Динамика обучения нейронной сети

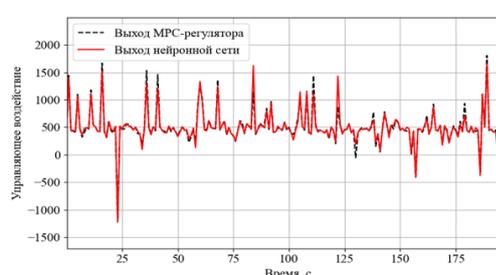


Рис. 7. Сравнение отклика MPC-регулятора и нейронной сети

Для сравнительного анализа эффективности алгоритмов управления были получены переходные характеристики системы по каналу управления, изображённые на рис. 8. Также на каждом шаге управления измерялось время вычисления управляющего сигнала, по результатам чего построены временные зависимости для обоих регуляторов (рис. 9).

Нейросетевой регулятор, работа которого показана на рисунке 9, хотя и характеризуется незначительным увеличением времени переходного процесса, демонстрирует высокое качество управления: переходный процесс остаётся устойчивым и достаточно быстрым, обеспечивая точный выход на уставку.

Кроме того, как показано на рис. 9, при использовании нейросетевого регулятора значительно сокращается время вычисления одного шага управления, что указывает на повышение вычислительной эффективности системы.

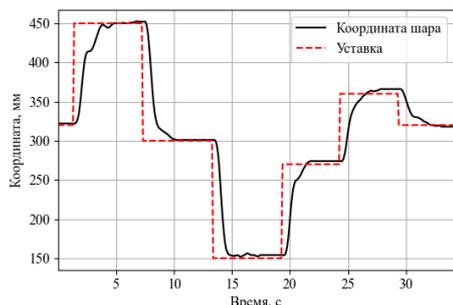


Рис. 8. Переходная характеристика системы с нейросетевым регулятором

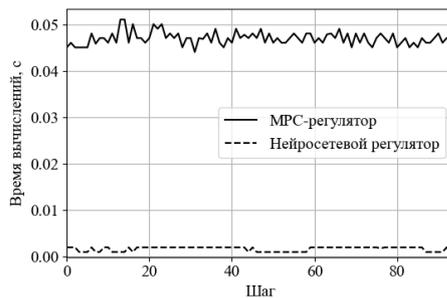


Рис. 9. Время вычисления управляющего воздействия

Для оценки производительности регуляторов проведен количественный анализ ключевых метрик. Сравнение показателей качества управления динамическим объектом при выполнении экспериментов показан в табл. 2.

Таблица 2

Сравнительные показатели качества управления

Показатель качества	Нейросетевой регулятор	MPC-регулятор
Перерегулирование, %	<1 %	<1 %
Время переходного процесса, с	2.08	1.61
Статическая ошибка, мм	3.5	2
Среднее время вычисления шага управления, мс	1.6	47

Из табл. 2 видно, что оба регулятора обеспечивают высокое качество управления при минимальном перерегулировании (менее 1%) и низкой статической ошибке. При этом нейросетевой регулятор демонстрирует лишь небольшое увеличение времени переходного процесса (2.08 с против 1.61 с у MPC), но значительно превосходит его по вычислительной эффективности: время расчёта одного шага управления сокращается примерно в 29 раз (1.6 мс против 47 мс).

Заключение. В данной работе предложен и исследован нейросетевой регулятор, обученный на основе модельно-прогнозирующего контроллера (MPC), для задачи стабилизации положения динамического объекта на подвижной платформе. Экспериментальные результаты показали, что нейросетевая модель способна воспроизводить динамику MPC с высокой точностью, обеспечивая аperiodический и устойчивый переходный процесс с минимальной статической ошибкой. При этом время вычисления управляющего воздействия сокращается примерно в 29 раз, что существенно повышает вычислительную эффективность системы и делает подход применимым в реальном времени для объектов с высокой частотой дискретизации.

Сравнительный анализ показателей качества управления (перерегулирование, время переходного процесса, статическая ошибка) подтвердил сопоставимость работы нейросетевого регулятора с классическим MPC, несмотря на незначительное увеличение времени переходного процесса. Такой результат демонстрирует потенциал использования нейросетевых методов для аппроксимации сложных оптимизационных регуляторов без значительных потерь в качестве управления. Предложенный подход открывает перспективы для дальнейшего применения нейросетевых регуляторов в задачах управления динамически сложными системами с ограниченными вычислительными ресурсами, а также для расширения на более сложные объекты с многомерной динамикой и нелинейными ограничениями.

Работа выполнена при поддержке гранта Российского научного фонда, проект № 25-61-00017.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Афонин В.В., Мурюмин С.М.* Обратные задачи оптимальной стабилизации со скалярным управлением // Вестник Мордовского университета. – 2017. – Т. 27, № 4. – С. 504-517. – DOI: 10.15507/0236-2910.027.201704.504-517.
2. *Yaseen M.G., Aljanabi M.* Recent Advances in Control Theory for Complex Systems // *Babylonian Journal of Mathematics*. – 2023. – P. 7-11.
3. *Голубев А.Е.* Стабилизация программных движений механических систем с учетом ограничений // Известия РАН. Теория и системы управления. – 2023. – № 4. – С. 153-167.
4. *Schwenzer M., Ay M., Bergs T., Abel D.* Review on Model Predictive Control: An Engineering Perspective // *The International Journal of Advanced Manufacturing Technology*. – 2021. – Vol. 117. – P. 1327-1349. – DOI: 10.1007/s00170-021-07682-3.
5. *Senthil Kumar Arumugasamy, Zainal Ahmad.* Model Predictive Control (MPC) and Its Current Issues in Chemical Engineering // *Chemical Engineering Communications*. – 2012. – 199 (4). – P. 472-511. – DOI: 10.1080/00986445.2011.592446.
6. *Шевлягин С.А., Торгашов А.Ю.* Управление технологическими процессами на основе прогнозирующих моделей: учеб. пособие для вузов. – Владивосток: Изд-во Дальневост. федерал. ун-та, 2024. – 84 с.
7. *Летихин Т.А.* Методы повышения быстродействия цифровых систем с линейной обратной связью // Вестник Санкт-Петербургского университета. Серия 10: Прикладная математика. Информатика. Процессы управления. – 2010. – № 4. – С. 96-108.
8. *McAllister R., Chua K., Calandra R. and Levine S.* Deep reinforcement learning in a handful of trials using probabilistic dynamics models // *In Advances in Neural Information Processing Systems*. – 2018. – P. 4754-4765.
9. *Khajanchi H.I., Bruno J.N., Adegbege A.A.* An Embedded FPGA Architecture for Real-Time Model Predictive Control // *IFAC-PapersOnLine*. – 2020. – Vol. 53 (2). – P. 7833-7838. – DOI: 10.1016/j.ifacol.2020.12.1886
10. *Zhang X., Bujarbaruah M., Borrelli F.* Near-Optimal Rapid MPC Using Neural Networks: A Primal-Dual Policy Learning Framework // *IEEE Transactions on Control Systems Technology*. – P. 1-13. – DOI: 10.1109/TCST.2020.3024571.
11. *Alsmeier H., Theiner L., Savchenko A., Mesbah A., Findeisen R.* Imitation Learning of MPC with Neural Networks: Error Guarantees and Sparsification // *IEEE 63rd Conference on Decision and Control*. – 2024. – P. 4777-4782. – DOI: 10.48550/arXiv.2501.03671.
12. *Gonzalez C., Asadi H., Kooijman L., Lim C.P.* Neural Networks for Fast Optimisation in Model Predictive Control: A Review // *CoRR*. – 2023. – DOI: 10.48550/ARXIV.2309.02668.
13. *Curtis C., Quackenbush T., Sorensen T., Wingate D., Killpack M.D.* Using First Principles for Deep Learning and Model-Based Control of Soft Robots // *Frontiers in Robotics and AI*. – 2021. – Vol. 8. – Article 654398. – DOI: 10.3389/frobt.2021.654398.
14. *Karg B., Lucia S.* Efficient Representation and Approximation of Model Predictive Control Laws via Deep Learning // *IEEE Transactions on Cybernetics*. – 2020. – Vol. 50, No. 9. – P. 3866-3878. – DOI: 10.1109/TCYB.2020.2999556.
15. *Phuong T.H., Belov M.P., Tran D.K.* Model predictive controller based on Laguerre functions for largeradio telescope servo control system // *IEEE Conf. El-ConRusNW, SPb*. – 2018. – P. 1020-1024.
16. *Белов М.П., Фьонг Ч.Х., Тхуй Д.В.* Адаптивное прогнозирующее управление следящими электроприводами нелинейных систем с упругими связями // *Известия СПбГЭТУ «ЛЭТИ»*. – 2019. – № 3. – С. 84-94.
17. *Filimonov A.B., Filimonov N.B.* Synthesis of Servo-systems on the Basis of the Apparatus of Linear-Quadratic Optimization // *Mekhatronika, avtomatizatsiya, upravlenie*. – 2016. – Vol. 17, No. 12. – P. 795-801. – DOI: 10.17587/mau.17.795-801.
18. *He Z., Wu J., Zhang J., Zhang S., Shi Y., Liu H., Sun L., Su Y., Leng X.* CDM-MPC: An Integrated Dynamic Planning and Control Framework for Bipedal Robots Jumping // *IEEE Robotics and Automation Letters*. – 2024. – Vol. 9. – P. 6672-6679. – DOI: 10.1109/LRA.2024.3408487.
19. *Ali A.M., Sha'aban Y.A., Salawudeen A.T., Haruna Z., Muhammad B., Mu'azu M.B., Alharthi A.* Optimized Model Predictive Control for Improving Dynamic Stability and Steering Accuracy in Multi-Axle Cranes // *PLoS One*. – 2025. – Vol. 20. – DOI: 10.1371/journal.pone.0324720.
20. *Hou B., Yin Z., Jin X., Fan Z., Wang H.* MPC-Based Dynamic Trajectory Spoofing for UAVs // *Drones*. – 2024. – Vol. 8, No. 10. – P. 602. – DOI: 10.3390/drones8100602.
21. *Tomás L., Lämmle M., Pfafferoth J.* Demonstration and Evaluation of Model Predictive Control (MPC) for a Real-World Heat Pump System in a Commercial Low-Energy Building for Cost Reduction and Enhanced Grid Support // *Energies*. – 2025. – Vol. 18, No. 6. – P 1434. – DOI: 10.3390/en18061434.

22. Wang H., Liu B., Ping X., An Q. Path-Tracking Control for Autonomous Vehicles Based on an Improved MPC // IEEE Access. – 2019. – Vol. 7. – P. 161064-161073. – DOI: 10.1109/ACCESS.2019.2944894.
23. Song H., Yue M., Qi G., Cai L., Zhao X. Longitudinal and Yaw Stability Control of Distributed Drive Vehicles Under Low Adhesion Conditions Based on MPC and Trigger Mechanism // Journal of Vibration and Control. – 2025. – Vol. 0, No. 0. – P. 1-17. – DOI: 10.1177/10775463251332835.
24. Wang Y., Sun K., Zhang W., Jin X. A Velocity-Adaptive MPC-Based Path Tracking Method for Heavy-Duty Forklift AGVs // Machines. – 2024. – Vol. 12. – P. 558. – DOI: 10.3390/machines12080558.
25. Benotsmane R., Kovács G. Optimization of Energy Consumption of Industrial Robots Using Classical PID and MPC Controllers // Energies. – 2023. – Vol. 16. – P. 3499. – DOI: 10.3390/en16083499.

REFERENCES

1. Afonin V.V., Muryumin S.M. Obratnye zadachi optimal'noy stabilizatsii so skalyarnym upravleniem [Inverse problems of optimal stabilization with scalar control], *Vestnik Mordovskogo universiteta* [Bulletin of the Mordovian University], 2017, Vol. 27, No. 4, pp. 504-517. DOI: 10.15507/0236-2910.027.201704.504-517.
2. Yaseen M.G., Aljanabi M. Recent Advances in Control Theory for Complex Systems, *Babylonian Journal of Mathematics*, 2023, pp. 7-11.
3. Golubev A.E. Stabilizatsiya programnykh dvizheniy mekhanicheskikh sistem s uchetom ogranicheniy [Stabilization of program movements of mechanical systems, taking into account restrictions], *Izvestiya RAN. Teoriya i sistemy upravleniya* [Izvestia RAS. Theory and control systems], 2023, No. 4, pp. 153-167.
4. Schwenzer M., Ay M., Bergs T., Abel D. Review on Model Predictive Control: An Engineering Perspective, *The International Journal of Advanced Manufacturing Technology*, 2021, Vol. 117, pp. 1327-1349. DOI: 10.1007/s00170-021-07682-3.
5. Senthil Kumar Arumugasamy, Zainal Ahmad. Model Predictive Control (MPC) and Its Current Issues in Chemical Engineering, *Chemical Engineering Communications*, 2012, 199 (4), pp. 472-511. DOI: 10.1080/00986445.2011.592446.
6. Shevlyagin S.A., Torgashov A.Yu. Upravlenie tekhnologicheskimi protsessami na osnove prognoziryushchikh modeley: ucheb. posobie dlya vuzov [Process management based on predictive models: a textbook for universities]. Vladivostok: Izd-vo Dal'nevost. federal. un-ta, 2024, 84 p.
7. Lepikhin T.A. Metody povysheniya bystrodeystviya tsifrovyykh sistem s lineynoy obratnoy svyaz'yu [Methods for increasing the speed of digital systems with linear feedback], *Vestnik Sankt-Peterburgskogo universiteta. Seriya 10: Prikladnaya matematika. Informatika. Protssesy upravleniya* [Bulletin of St. Petersburg University. Series 10: Applied Mathematics. Computer science. Management processes], 2010, No. 4, pp. 96-108.
8. McAllister R., Chua K., Calandra R. and Levine S. Deep reinforcement learning in a handful of trials using probabilistic dynamics models, *In Advances in Neural Information Processing Systems*, 2018, pp. 4754-4765.
9. Khajanchi H.I., Bruno J.N., Adegbege A.A. An Embedded FPGA Architecture for Real-Time Model Predictive Control, *IFAC-PapersOnLine*, 2020, Vol. 53 (2), pp. 7833-7838. DOI: 10.1016/j.ifacol.2020.12.1886
10. Zhang X., Bujarbaruah M., Borrelli F. Near-Optimal Rapid MPC Using Neural Networks: A Primal-Dual Policy Learning Framework, *IEEE Transactions on Control Systems Technology*, pp. 1-13. DOI: 10.1109/TCST.2020.3024571.
11. Alsmeier H., Theiner L., Savchenko A., Mesbah A., Findeisen R. Imitation Learning of MPC with Neural Networks: Error Guarantees and Sparsification, *IEEE 63rd Conference on Decision and Control*, 2024, pp. 4777-4782. DOI: 10.48550/arXiv.2501.03671.
12. Gonzalez C., Asadi H., Kooijman L., Lim C.P. Neural Networks for Fast Optimisation in Model Predictive Control: A Review, *CoRR*, 2023. DOI: 10.48550/ARXIV.2309.02668.
13. Curtis C., Quackenbush T., Sorensen T., Wingate D., Killpack M.D. Using First Principles for Deep Learning and Model-Based Control of Soft Robots, *Frontiers in Robotics and AI*, 2021, Vol. 8, Article 654398. DOI: 10.3389/frobt.2021.654398.
14. Karg B., Lucia S. Efficient Representation and Approximation of Model Predictive Control Laws via Deep Learning, *IEEE Transactions on Cybernetics*, 2020, Vol. 50, No. 9, pp. 3866-3878. DOI: 10.1109/TCYB.2020.2999556.
15. Phuong T.H., Belov M.P., Tran D.K. Model predictive controller based on Laguerre functions for largerradio telescope servo control system, *IEEE Conf. El-ConRusNW*, SPb., 2018, pp. 1020-1024.
16. Belov M.P., Fyong Ch.Kh., Tkhuynh D.V. Adaptivnoe prognoziryushchee upravlenie sledyashchimi elektroprivodami nelineynykh sistem s uprugimi svyazyami [Adaptive predictive control of tracking electric drives of non-linear systems with elastic bonds], *Izvestiya SPbGETU «LETI»* [Izvestia SPbGETU «LETI»], 2019, No. 3, pp. 84-94.

17. Filimonov A.B., Filimonov N.B. Synthesis of Servo-systems on the Basis of the Apparatus of Linear-Quadratic Optimization, *Mekhatronika, avtomatizatsiya, upravlenie*, 2016, Vol. 17, No. 12, pp. 795-801. DOI: 10.17587/mau.17.795-801.
18. He Z., Wu J., Zhang J., Zhang S., Shi Y., Liu H., Sun L., Su Y., Leng X. CDM-MPC: An Integrated Dynamic Planning and Control Framework for Bipedal Robots Jumping, *IEEE Robotics and Automation Letters*, 2024, Vol. 9, pp. 6672-6679. DOI: 10.1109/LRA.2024.3408487.
19. Ali A.M., Sha'aban Y.A., Salawudeen A.T., Haruna Z., Muhammad B., Mu'azu M.B., Alharthi A. Optimized Model Predictive Control for Improving Dynamic Stability and Steering Accuracy in Multi-Axle Cranes, *PLoS One*, 2025, Vol. 20. DOI: 10.1371/journal.pone.0324720.
20. Hou B., Yin Z., Jin X., Fan Z., Wang H. MPC-Based Dynamic Trajectory Spoofing for UAVs, *Drones*, 2024, Vol. 8, No. 10, pp. 602. DOI: 10.3390/drones8100602.
21. Tomás L., Lämmle M., Pfafferoth J. Demonstration and Evaluation of Model Predictive Control (MPC) for a Real-World Heat Pump System in a Commercial Low-Energy Building for Cost Reduction and Enhanced Grid Support, *Energies*, 2025, Vol. 18, No. 6, pp 1434. DOI: 10.3390/en18061434.
22. Wang H., Liu B., Ping X., An Q. Path-Tracking Control for Autonomous Vehicles Based on an Improved MPC, *IEEE Access*, 2019, Vol. 7, pp. 161064-161073. DOI: 10.1109/ACCESS.2019.2944894.
23. Song H., Yue M., Qi G., Cai L., Zhao X. Longitudinal and Yaw Stability Control of Distributed Drive Vehicles Under Low Adhesion Conditions Based on MPC and Trigger Mechanism, *Journal of Vibration and Control*, 2025, Vol. 0, No. 0, pp. 1-17. DOI: 10.1177/10775463251332835.
24. Wang Y., Sun K., Zhang W., Jin X. A Velocity-Adaptive MPC-Based Path Tracking Method for Heavy-Duty Forklift AGVs, *Machines*, 2024, Vol. 12, pp. 558. DOI: 10.3390/machines12080558.
25. Benotsmane R., Kovács G. Optimization of Energy Consumption of Industrial Robots Using Classical PID and MPC Controllers, *Energies*, 2023, Vol. 16, pp. 3499. DOI: 10.3390/en16083499.

Комаров Борис Александрович – Национальный исследовательский Томский политехнический университет; e-mail: bak7@tpu.ru; г. Томск, Россия; инженер; аспирант отделения интеллектуальных систем ИШИНЭС.

Леонов Сергей Владимирович – Национальный исследовательский Томский политехнический университет; e-mail: leonov@tpu.ru; г. Томск, Россия; к.т.н.; доцент отделения интеллектуальных систем ИШИНЭС.

Мамонова Татьяна Егоровна – Национальный исследовательский Томский политехнический университет; e-mail: stepte@tpu.ru; г. Томск, Россия; к.т.н.; доцент отделения интеллектуальных систем ИШИНЭС.

Komarov Boris Aleksandrovich – National Research Tomsk Polytechnic University; e-mail: bak7@tpu.ru; Tomsk, Russia; engineer, graduate student.

Leonov Sergey Vladimirovich – National Research Tomsk Polytechnic University; e-mail: leonov@tpu.ru; Tomsk, Russian; cand. of eng. sc.; associate professor.

Mamonova Tatyana Egorovna – National Research Tomsk Polytechnic University; e-mail: stepte@tpu.ru; Tomsk, Russia; cand. of eng. sc.; associate professor.

УДК 681.5

DOI 10.18522/2311-3103-2025-6-287-298

А.И. Татауров, В.Е. Вавилов

АНАЛИЗ ТРАДИЦИОННЫХ И НЕЙРОСЕТЕВЫХ МЕТОДОВ УПРАВЛЕНИЯ ЭЛЕКТРОПРИВОДАМИ В РОБОТОТЕХНИКЕ И ПЕРСПЕКТИВЫ ГИБРИДНЫХ ПОДХОДОВ

Целью настоящего исследования является сравнительный анализ традиционных и нейросетевых методов управления электроприводами в робототехнике, с акцентом на выявление их сильных и слабых сторон, определение областей применения и оценку перспектив развития гибридных подходов. Эффективное управление электроприводами является критически важным для современных робототехнических систем, которые должны демонстрировать высокую производительность, надежность и универсальность в различных областях применения. В частности, актуальными задачами являются обеспечение высокоточного отслеживания траектории, энергоэффек-