

ИНТЕЛЛЕКТУАЛЬНЫЕ РОБАСТНЫЕ КОНТРОЛЛЕРЫ ТРИБОТРОННЫХ КОНИЧЕСКИХ ОПОР СКОЛЬЖЕНИЯ

© 2024

- Ю. Н. Казаков** аспирант кафедры мехатроники, механики и робототехники;
Орловский государственный университет имени И.С. Тургенева;
KazakYurii@yandex.ru
- Д. В. Шутин** кандидат технических наук, доцент кафедры мехатроники, механики
и робототехники;
Орловский государственный университет имени И.С. Тургенева;
rover.ru@gmail.com
- Л. А. Савин** доктор технических наук, профессор кафедры мехатроники, механики
и робототехники;
Орловский государственный университет имени И.С. Тургенева;
savin3257@mail.ru

Представлены результаты разработки средств интеллектуального робастного управления параметрами триботронной роторно-опорной системы с коническим подшипником со смещаемой втулкой. Предложенный контроллер реализован на основе глубокого нейросетевого Q-обучения с подкреплением (DQN), синтезированного на основе верифицированной численной модели роторно-опорной системы. Стратегия управления включала в себя одновременное управление положением вала и трением в смазочном слое. Помимо синтеза управления для детерминированной системы также представлен новый метод синтеза робастного DQN-контроллера для системы со стохастичностью параметров. Метод позволяет учитывать неопределённости в системе на этапе обучения посредством случайного варьирования параметров её численной модели. Численное тестирование полученных контроллеров показывает лучшую способность контроллера, обученного с учётом неопределённостей, справляться с переменными нагрузками, а также прогнозировать возможные изменения в системе и превентивно переводить систему в более выгодные состояния.

Триботронные опоры; конические подшипники; интеллектуальные контроллеры; DQN; оптимальное управление; робастное управление

Цитирование: Казаков Ю.Н., Шутин Д.В., Савин Л.А. Интеллектуальные робастные контроллеры триботронных конических опор скольжения // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2024. Т. 23, № 3. С. 94-110. DOI: 10.18287/2541-7533-2024-23-3-94-110

Введение

Триботронные опорные узлы представляют собой мультифизическую систему, основанную на совокупности гидродинамических, теплофизических, динамических явлений, объединённых информационными связями. Такие системы характеризуются комплексным характером взаимосвязей в них и стохастичностью рабочих параметров. Управляемые опоры позволяют системе в процессе работы адаптироваться к изменяющимся условиям, но для этого требуются специализированные подходы к построению систем управления.

Триботронные опоры стали разрабатываться и исследоваться сравнительно недавно по сравнению с традиционными конструкциями опор скольжения [1; 2]. Первоначально управляемые опоры выполняли в первую очередь функцию виброгашения. Используемые для этого контроллеры основывались на классических пропорциональных [3], пропорционально-дифференциальных [4], пропорционально-интегрально-дифференциальных [5] регуляторах. В отдельных случаях для устранения недостатков простейших законов управления в условиях нелинейности свойств роторно-опорных

систем применялись более продвинутые методы, такие, как нечёткая логика [6; 7], линейно-квадратические регуляторы [8], H^∞ [9] контроллеры. В [10] представлено модельно-предиктивное управление активно смазываемой опоры. Вместе с тем, контроллер был синтезирован на линеаризованной модели системы, не учитывающей в полной мере присущие ей нелинейности.

Более полный учёт комплексных взаимосвязей в триботронной системе роторно-опора может быть реализован посредством синтеза контроллеров на основе глубокого нейросетевого Q-обучения с подкреплением (DQN) [11 – 13], которое происходит с использованием нелинейных численных моделей. Такие контроллеры являются, по своей сути, оптимальными, поскольку базируются на поиске оптимальной политики управления в процессе обучения с подкреплением на основе агентного подхода. Ранее был разработан ряд базовых DQN-регуляторов для задач коррекции момента трения [14] и снижения вибраций [15] в управляемых конических опорах. Вместе с тем, другим преимуществом интеллектуальных контроллеров на основе обучения с подкреплением является возможность задания сложных стратегий управления [16 – 19]. В настоящей статье представлены развитие подхода и реализация более комплексной стратегии управления на основе DQN-подхода, учитывающей одновременно как трение в опорах, так и вибрации в роторно-опорной системе.

Ранее в научной литературе не было представлено каких-либо подходов, целенаправленно обеспечивающих робастность управления на основе DQN-контроллеров. Для триботронных опор этот фактор имеет особенное значение, поскольку они нередко функционируют в условиях сложных переменных нагрузок, а также в условиях вариативности свойств самой системы, например, в силу изменения температурных режимов, свойств смазочных материалов, износа её компонентов.

Данная работа представляет новый подход к синтезу робастных интеллектуальных контроллеров триботронных опорных узлов на основе обучения с подкреплением. Предложенный метод позволяет учитывать наличие неопределенностей в системе уже на этапе обучения контроллера посредством варьирования тех параметров численной модели, которые характеризуются наличием неопределенностей в реальных системах. В результате в процессе обучения и оптимизации политики управления производится поиск наиболее устойчивых к таким неопределенностям законов регулирования. В статье представлены результаты сравнения обученного таким образом робастного контроллера с базовым DQN-контроллером, синтезированным без учёта неопределенностей параметры системы и нагрузок. Кроме того, представлены результаты анализа робастности полученных контроллеров в условиях вариативности внешних нагрузок. Сделаны выводы о преимуществах, недостатках и перспективах существующих и предложенных решений в области управления триботронными опорами.

Объект управления и его модель

Регулируемый конический подшипник

Ключевым объектом в данной работе является роторная система с коническим подшипником жидкостного трения, в конструкции которого предусмотрена возможность осевого смещения втулки относительно вала посредством линейного привода. Это дает возможность изменения средней толщины смазочного слоя, что влияет на величину генерируемых им сил, а, следовательно, на трибологические и динамические параметры системы. Схема триботронного конического подшипника жидкостного трения представлена на рис. 1, а основные параметры рассмотренной роторной системы представлены в табл. 1.




Рис. 1. Схема конического подшипника жидкостного трения:
 а – конический подшипник жидкостного трения;
 б – развёртка смазочного слоя в декартовых координатах

Таблица 1. Геометрические и силовые параметры роторно-опорного узла

| Параметр | Значение |
|--|----------|
| Длина подшипника l_3 , мм | 26 |
| Начальный радиальный зазор h_0 , мкм | 100 |
| Диапазон изменения радиального зазора подшипника h_0 , мкм | 73...138 |
| Малый радиус подшипника r_0 , мм | 20 |
| Угол конусности α , град | 3 |
| Длина ротора l_r , мм | 380 |
| Масса ротора m , кг | 3 |
| Частота вращения ротора n , об/мин | 3000 |
| Давление подачи смазки (вода) p_0 , МПа | 0,12 |

Ключевым элементом рассматриваемого подшипника является коническая втулка с осевой подачей смазочного материала, в которой вращается коническая цапфа ротора. Математическая модель конического подшипника основана на численном решении модифицированного уравнения Рейнольдса методом конечных разностей [14; 15]:

$$h^3 \frac{\partial}{\partial \beta_1} \left(\beta_1 \frac{\partial p}{\partial \beta_1} \right) + \frac{1}{\beta_1} \frac{\partial}{\partial \beta_2} \left(h^3 \frac{\partial p}{\partial \beta_2} \right) = \mu u_1 6h + \mu u_2 6 \frac{\partial h}{\partial \beta_2} - \mu 12 u_3 \beta_1, \quad (1)$$

где $\beta_1, \beta_2, \beta_3$ – радиальная, угловая и осевая координаты; h – функция радиального зазора подшипника скольжения; μ – динамическая вязкость смазочного материала; p – искомое давление смазочного материала в зазоре подшипника скольжения.

Компоненты вектора скорости течения жидкости:

$$u_1 = V_3;$$

$$u_2 = \omega \left(r_0 + \frac{\beta_1 - \beta_1^-}{l_3} (r_1 - r_0) \right) + V_1 \cos \left(\frac{\beta_1^- \beta_2}{r_0} \right) - V_2 \sin \left(\frac{\beta_1^- \beta_2}{r_0} \right);$$

$u_3 = V_1 \sin\left(\frac{\beta_1^- \beta_2^-}{r_0}\right) + V_2 \cos\left(\frac{\beta_1^- \beta_2^-}{r_0}\right)$, где V_1, V_2, V_3 – линейные скорости движения цапфы ротора в декартовых координатах; ω – угловая скорость вращения ротора; r_0 – малый радиус подшипника; r_1 – большой радиус подшипника, β_1^- – начальное значение координаты β_1 .

Функция радиального зазора конического подшипника жидкостного трения с учётом осевого положения втулки:

$$h = h(\beta_2) = \left((h_0 + X_3 \sin \alpha) - X_1 \sin\left(\frac{\beta_1^- \beta_2^-}{r_0}\right) - X_2 \cos\left(\frac{\beta_1^- \beta_2^-}{r_0}\right) \right) \cos \alpha, \quad (2)$$

где α – угол конусности; X_i – координаты положения вала в подшипнике.

Решением гидродинамической задачи являются значения сил смазочного слоя, действующие на цапфу вала:

$$\begin{aligned} F_1 &= - \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} p \cos \alpha \cos \varphi \beta_1 d \beta_1 H_2 d \beta_2, \\ F_2 &= - \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} p \cos \alpha \sin \varphi \beta_1 d \beta_1 H_2 d \beta_2, \\ F_3 &= \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} p \sin \alpha \beta_1 d \beta_1 H_2 d \beta_2, \end{aligned} \quad (3)$$

где F_i – реакции смазочного слоя; H_i – коэффициенты Лямэ; $\varphi = \frac{\beta_1^- \beta_2^-}{r_0}$ – угол.

В работе используется модель ротора как жёсткого тела, работающего без перекосов на докритических частотах. На ротор действует совокупность сил, включая рассчитанные силы смазочного слоя F_i , а также силы дисбаланса:

$$F_{imb} = md \omega^2 \begin{bmatrix} \cos \omega t \\ \sin \omega t \\ 0 \end{bmatrix}, \quad (4)$$

где md – дисбаланс, ω – угловая скорость.

Момент вязкого трения в подшипнике рассчитывается по следующей формуле:

$$M = -r \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} \left(\frac{\partial p}{\partial \beta_2} \frac{h}{2\beta_1} + \frac{u_2 \mu}{h} \right) \beta_1 d \beta_1 H_2 d \beta_2, \quad (5)$$

где r – радиус вала.

Валидация представленной модели с использованием экспериментальных данных была представлена в [14]. На основании её результатов используемые в данной статье математическая и численная имитационная модели роторно-опорной системы считаются адекватными, а результаты проведенных с их использованием расчётов – имеющими достаточную степень достоверности.

DQN управление

DQN метод является одним из вариантов Q-обучения, в котором для формирования искомой политики поведения контроллера используются искусственные нейронные сети (ИНС). Метод реализует агентный подход, при котором в ходе обучения с подкреплением используются данные численной модели для итеративной оценки оптимальности решения задачи. DQN-agent на каждом временном шаге t получает информацию о состоянии системы S_t , на основе используемых параметров наблюдения происходит генерация управляющего сигнала A_t , в ответ на который рассчитывается вознаграждение r_t .

Во время обучения агент обучает критика $q(S, A)$ предсказывать будущую награду, которую получит алгоритм, обновляя веса ИНС критика на каждом шаге [20]:

$$g_t = r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} + \dots, \quad (6)$$

где γ – дисконт-фактор.

В процессе обучения необходимо добиться минимизации ошибки между обученной функцией $q(S, A)$ и ожидаемой оптимальной функцией $q^*(S, A)$, которую можно оценить с помощью уравнения Беллмана [20]:

$$q_t^*(S_t, A_t) = r_t + \gamma \max_A [q_{t+1}(S_{t+1}, A_{t+1})]. \quad (7)$$

В роли критика в данном алгоритме выступает искусственная нейронная сеть $q(S, A)$, которая минимизирует функцию потерь [20]:

$$L(\Theta^{(k)}) = \frac{1}{m} \sum_{i=1}^m \left(y_i - q(S_i, A_i | \Theta^{(k)}) \right)^2, \quad (8)$$

где $\Theta^{(k)}$ – веса искусственной нейронной сети; m – количество тренировочных примеров в одном мини-батче; $y_i = r_i + \gamma \max_A [q_{t+1}(S_{t+1}, A_{t+1})]$ – оценка будущего вознаграждения.

В данной работе критик основан на свёрточной искусственной нейронной сети, структура которой представлена на рис. 2.

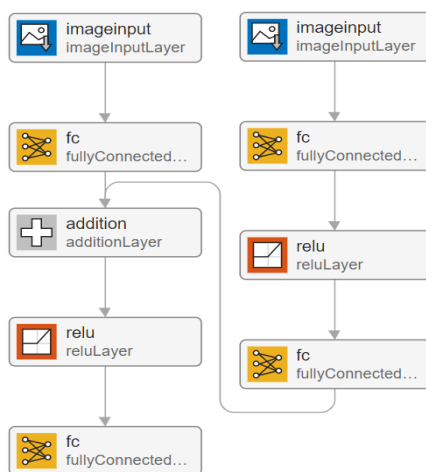


Рис. 2. Свёрточная искусственная нейронная сеть, реализующая критика в DQN-подходе

Искусственная нейронная сеть, представленная на рис. 2, состоит из трёх скрытых слоёв с 14, 18 и 18 нейронами, соответственно. При обучении в качестве входных параметров используются параметры наблюдения системы: $X_1, X_2, X_3, M, \Delta h$. Параметр Δh является безразмерным и отражает степень приближения цапфы вала в подшипнике к установленной предельной величине эксцентриситета. Такая величина выбирается из соображений безопасной работы роторно-опорной системы, в частности, минимизации риска механического контакта статора и ротора. В данной работе была установлена граница, равная $0,85h_0$, а параметр Δh вычисляется по следующей формуле:

$$\Delta h = \frac{e}{0,85h_0}, \quad (9)$$

где $e = \sqrt{X_1^2 + X_2^2}$, h_0 – радиальный зазор при данном осевом положении вала.

В свою очередь, для системы было установлено условие прерывания расчёта по аварийному событию, заданное следующим образом:

$$isdone = \begin{cases} \text{if } e \geq 0,85h_0; \\ \text{if } M \geq 7,5 \cdot 10^{-3}. \end{cases} \quad (10)$$

Награда, получаемая агентом в процессе обучения на каждом временном шаге, рассчитывается по следующей формуле:

$$reward = \begin{cases} \Delta h & \text{if } e < 0,85h_0; \\ -80 & \text{if } isdone = true. \end{cases} \quad (11)$$

Результаты

Расчёты в рамках представленного исследования проводились в программном пакете MATLAB с модулем Simulink. Модель твёрдого ротора была разработана с использованием библиотеки Simscape Multibody, для реализации DQN-контроллера использовалась библиотека Reinforcement Learning. Общая структура модели в среде Simulink показана на рис. 3. Для всех расчётов использовался ПК следующей конфигурации: процессор Intel Core i5-11600K 3.90 GHz, видеокарта NVIDIA T1000, 16 Гб оперативной памяти.

Модель роторной системы включала в себя основные блоки твёрдотельных моделей ротора и подшипника. Реакции подшипника и момент трения рассчитывались на базе искусственных нейронных сетей. Также представлены блоки для расчёта силы дисбаланса, осевой силы, создаваемой на торец вала от давления подачи жидкости, а также реакция демпфера на осевое смещение подшипника. Также в модели использовался блок контроллера на базе DQN-агента.

Базовый вариант DQN-контроллера был синтезирован на основе уравнений (6) – (8). Для обучения использовались следующие гиперпараметры: интенсивность обучения $LearnRate = 0,001$; параметры $GradientThreshold = 1$; $TargetSmoothFactor = 0,001$; $ExperienceBufferLength = 100000$; $DiscountFactor = 0,95$; $MiniBatchSize = 250$, оптимизатор – Adam.

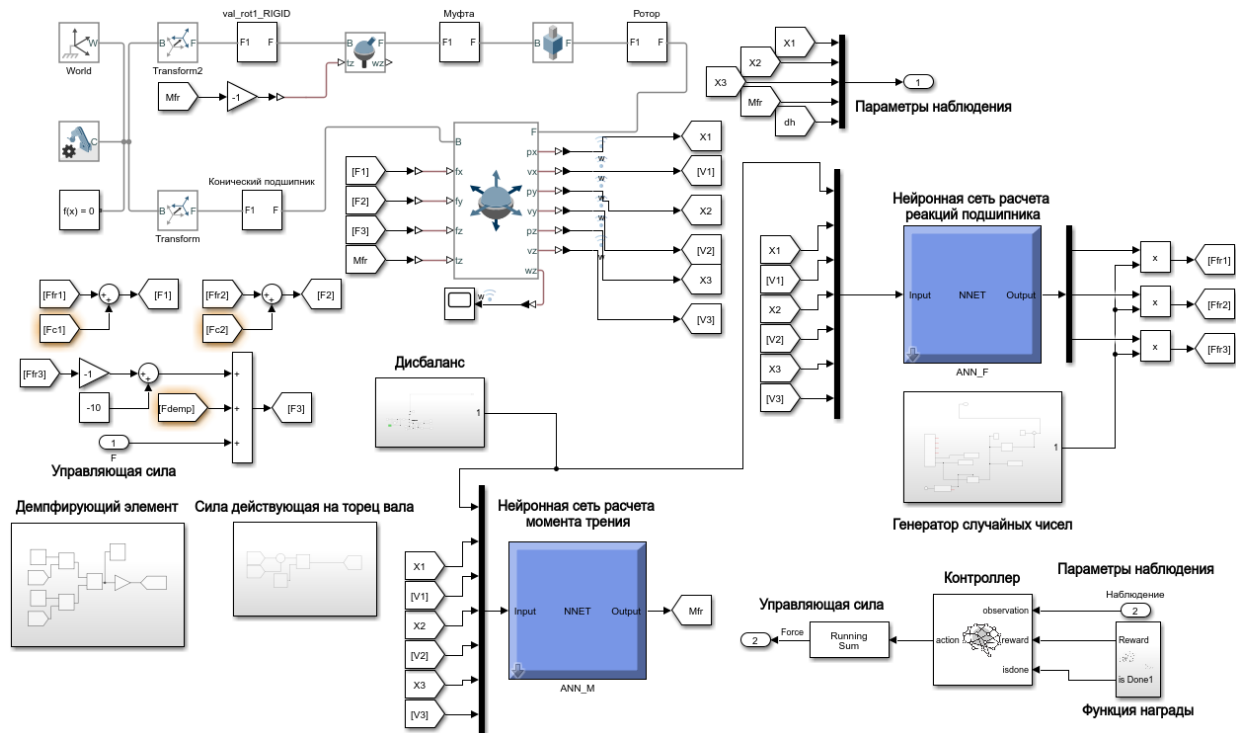


Рис. 3. Структура модели роторно-опорной системы в среде Simulink

Для непосредственного синтеза контроллеров был создан обучающий сценарий, в течение которого происходит двухкратное изменение нагрузки в виде резкого повышения дисбаланса в системе. Длительность сценария составляла 5 секунд. В моменты времени 1,25 с и 3,25 с в системе возникал дисбаланс величиной $m_u d = 7 \cdot 10^{-5}$ и длительностью 0,75 с. Задачей контроллера была генерация управляющих сигналов, приводящих к осевому смещению подвижной втулки с соответствующим изменением среднего зазора и сил смазочного слоя. Контроллер мог изменять управляющие воздействия с частотой 10 Гц. Максимальное возможное осевое смещение втулки относительно начального положения составляло от 1,2 мм до $-0,5$ мм. Для тестирования работы контроллеров также был создан дополнительный сценарий работы с дисбалансом, величина которого монотонно увеличивалась от $2 \cdot 10^{-5}$ до $9,5 \cdot 10^{-5}$ в течение 3,6 с.

Для обучения робастного контроллера была произведена предварительная оценка неопределённостей, возможных в рассматриваемой роторно-опорной системе. Для этого были выделены факторы, оказывающие наиболее значительное влияние на силовые параметры триботронной опоры.

1. Температура смазочного материала, которая зависит как от внешних условий, так и от работы самого опорного узла, поскольку разные управляемые состояния характеризуются разницей в величии вязкого трения в смазочном слое, а значит и в различных уровнях повышения температуры в нем. В свою очередь, температура оказывает влияние на вязкость смазочного материала, а значит, согласно уравнению Рейнольдса (1), и на несущую способность подшипника. Температурный режим для рассмотренной системы составлял 15...25 градусов Цельсия без учёта теплогенерации в подшипниках, а с её учётом он может быть расширен до 15...45 градусов Цельсия, согласно экспериментальным данным [21; 22]. Для смазочного материала (воды) это даёт изменение вязкости в диапазоне 0,6...1,14 мПа·с (в обратной пропорции).

2. Изменения температуры в опоре также приводит к температурным деформациям втулки и вала, что влияет на величину зазора в подшипнике, а, следовательно, на величину несущей способности. Для материалов пары трения сталь-бронза указанный выше температурный диапазон даёт изменение зазора до 5,4 мкм [23].

3. Возможная неравномерность скорости вращения вала, которая также оказывает влияние на несущую способность подшипника, принимается в 5% от номинальной установившейся скорости [24].

Для указанных диапазонов изменения параметров был произведён расчёт возможных значений несущей способности опоры при номинальном (центральном) положении втулки. Она варьировалась в диапазоне от 32,2 до 44,8 Н, что позволяет оценить величину неопределённости сил смазочного слоя как $\nu = \pm 20\%$ от номинального значения при нормальных условиях. Таким образом, при обучении робастного DQN-R регулятора в модель системы была добавлена вариабельность сил смазочного слоя в указанных пределах. В целях исследования чувствительности характеристик получаемого робастного регулятора к величине неопределённости, было обучено два варианта такого регулятора, с $\nu_1 = 10\%$ и $\nu_2 = 20\%$. Данные регуляторы поименованы, соответственно, DQN-R1 и DQN-R2. Величина отклонения при этом задавалась случайной величиной с равномерным законом распределения, значение которой изменялось на каждой эпохе обучения контроллера. Результаты процесса обучения DQN и DQN-R регуляторов представлены на рис. 4.

Тестирование контроллеров включало в себя два этапа. На первом этапе оценивались различия в поведении контроллеров при реализации одного сценария управления, на котором производилось обучение, но при различных состояниях опоры по несущей способности, находящихся на границе диапазонов обучения. Таким образом оценивалась способность регулятора выполнять свои функции в условиях неопределённостей внутренних параметров самой системы. В качестве сценария нагружения системы использовался тот же сценарий, что и в процессе обучения. Результаты тестирования контроллеров представлены на рис. 5.

Рис. 5, а, б показывают поведение управляемой системы с DQN и DQN-R1 регуляторами, когда фактическая величина сил смазочного слоя составляет 90% (рис. 5, а) и 110% (рис. 5, б) от номинальной. В целом, оба регулятора демонстрируют схожую политику управления. Ей свойственно превентивное уменьшение зазора перед увеличением дисбаланса, после чего регуляторы стремятся уменьшить момент трения за счёт увеличения зазора и смещения втулки в положительную область. Вместе с тем, последнее действие приводит к увеличению амплитуды колебаний ротора. За счёт оптимизации политики в процессе обучения регуляторы переводят систему в установившееся состояние вблизи установленной границы $0,85h_0$. Данное состояние характеризуется допустимыми величинами перемещений цапфы и минимально возможным при этом моментом трения в смазочном слое. При этом управляющие сигналы контроллеров DQN и DQN-R1 в основном идентичны, однако робастный DQN-R1 регулятор обеспечивает несколько более плавное изменение управляющих сигналов при смене режимов нагружения.

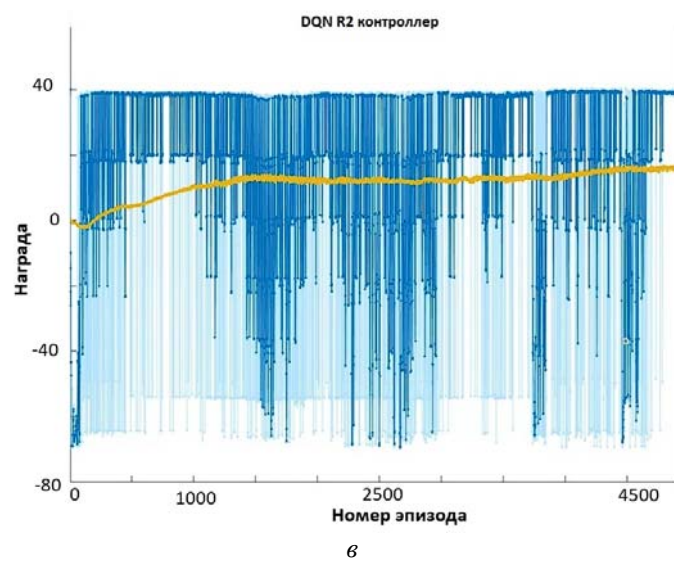

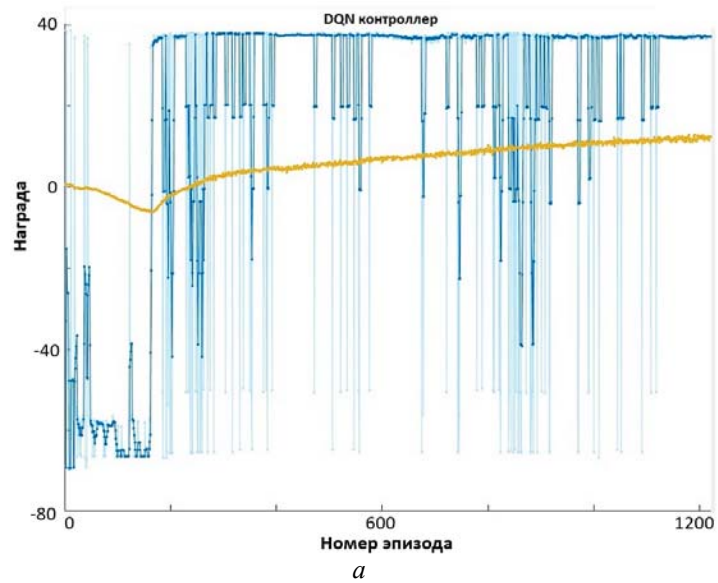
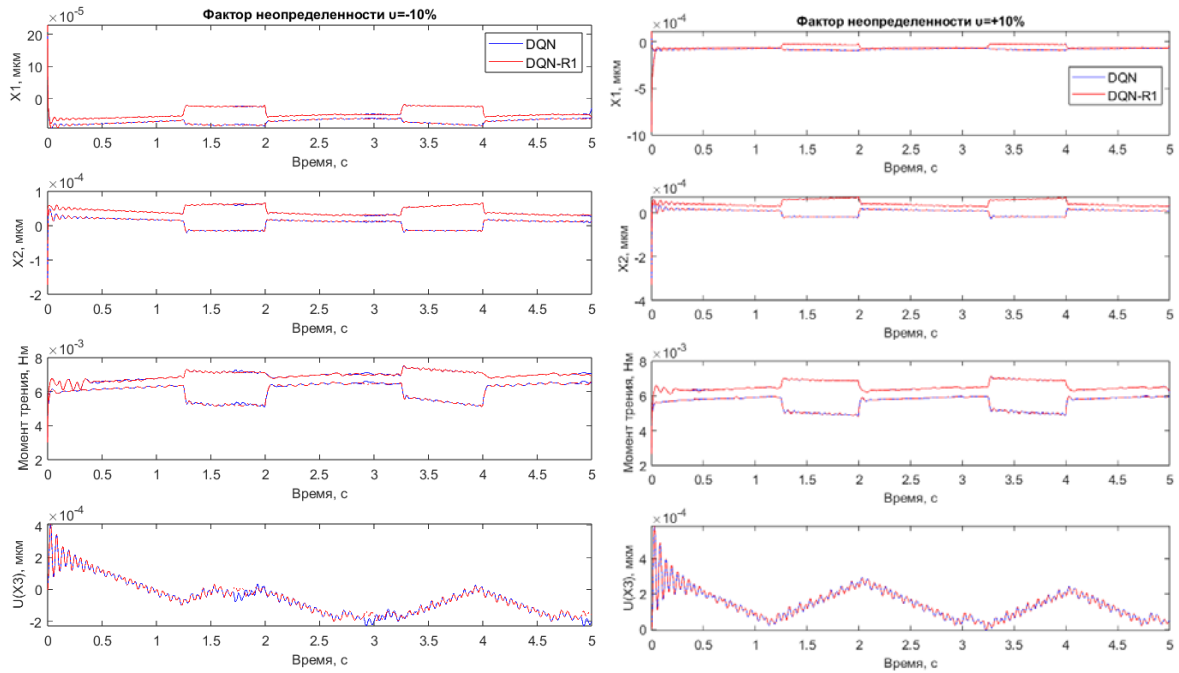
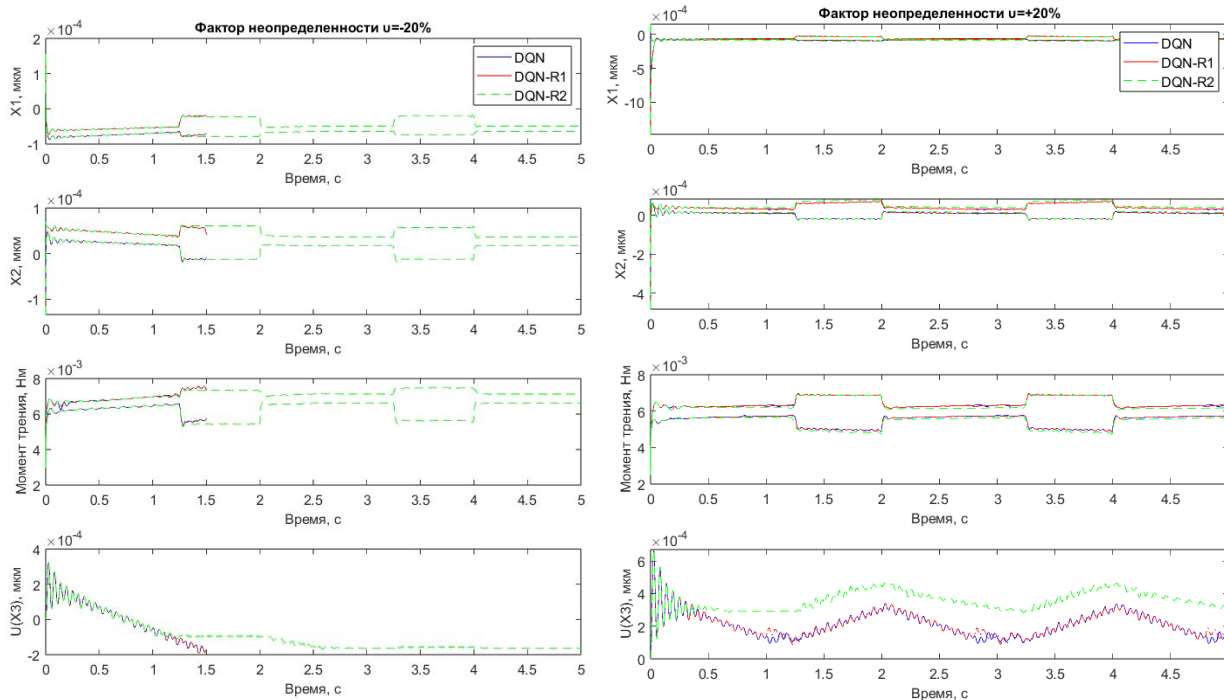


Рис. 4. Процесс обучения контроллеров: а – DQN; б – DQN-R1; в – DQN-R2



а

б



в

г

Рис. 5. Тестирование регуляторов при наибольших отклонениях параметрах системы (сигналы перемещений представлены их огибающими):
 а – $\nu = -10\%$; б – $\nu = 10\%$; в – $\nu = -20\%$; г – $\nu = 20\%$

Рис. 5, в, г показывают поведение управляемой системы с DQN и DQN-R2 регуляторами, когда фактическая величина сил смазочного слоя составляет 80% (рис. 5, в) и 120% (рис. 5, г) от номинальной. В данном случае между контроллерами наблюдаются более существенные различия в реализуемой политике управления, чем для случая обучения с установленным уровнем неопределённости $\nu = 10\%$. Ключевым отличием является то, что при снижении несущей способности опоры на 20% DQN и DQN-R2 регуляторы допускают превышение установленной границы перемещений цапфы по прошествии приблизительно 1,5 секунды сценария. В тех же условиях DQN-R2 обеспечивает полное выполнение сценария, не допуская аварийного режима работы. Это обеспечивается более сдержанной политикой реагирования на возмущающие воздействия, что приводит к менее выраженным колебаниям управляющего сигнала, как высоко-, так и низкочастотных.

На втором этапе тестирования оценивались различия в поведении синтезированных контроллеров при номинальном состоянии системы, но с различными величинами внешнего воздействия. Для этого к системе применялась непрерывно изменяющаяся величина дисбаланса ротора, которая равномерно возрастала от $2 \cdot 10^{-5}$ до $9,5 \cdot 10^{-5}$ в течение 3,6 секунд тестового сценария. В этом сценарии также была предусмотрена аварийная остановка системы при достижении цапфой относительного эксцентриситета $e = 0,85$, при котором возможен переход к смешанному режиму трения в подшипнике и существует риск повреждения трущихся поверхностей. Результаты тестирования показаны на рис. 6.

В данном случае также наблюдаются значительные различия между рассмотренными вариантами контроллеров. Как и в случае с неопределенностями внутренних параметров роторно-опорной системы, DQN-R2 регулятор обеспечивает более сдержанную стратегию управления, лишь незначительно подстраивая положение исполнительного органа в ответ на увеличивающееся внешнее воздействие. При этом в течение всего времени моделирования цапфа ротора не выходила за установленное предельное значение эксцентриситета. В тех же условиях DQN-R2 регулятор показывает более значительные колебания управляющего сигнала, первоначально снижая его, а затем вновь повышая. В совокупности с дополнительной неравномерностью сигнала из-за наличия в нём более высокочастотной составляющей, система вышла на аварийный режим через 4 секунды сценария. Обычный DQN-регулятор при этом допустил переход к аварийному режиму уже через 3,6 секунды, и показывал в целом меньшую способность адаптироваться к изменению внешнего воздействия.

Таким образом, предложенный метод синтеза робастного управления на основе DQN алгоритмов показал преимущества в условиях неопределённостей, как во внутренних параметрах системы, так и во внешних воздействиях. Вероятно, в процессе обучения регулятора стратегии управления с большими скоростями изменения управляющих сигналов оказывались неэффективными. В условиях изменчивости параметров системы это приводило к выходу системы за установленные пределы и начислению штрафов. При этом подобные изменения в выбранной политике регулирования становятся более заметными при повышении уровня неопределённости в модели системы. Между DQN-R1 и DQN-R2 контроллерами наблюдаются существенно большие различия в политике управления, чем между DQN и DQN^R₁₀. Это говорит о нелинейном изменении свойств регулятора в ответ на изменение величины проявляющихся в системе неопределённостей. Данный вопрос требует дальнейшего углублённого изучения.

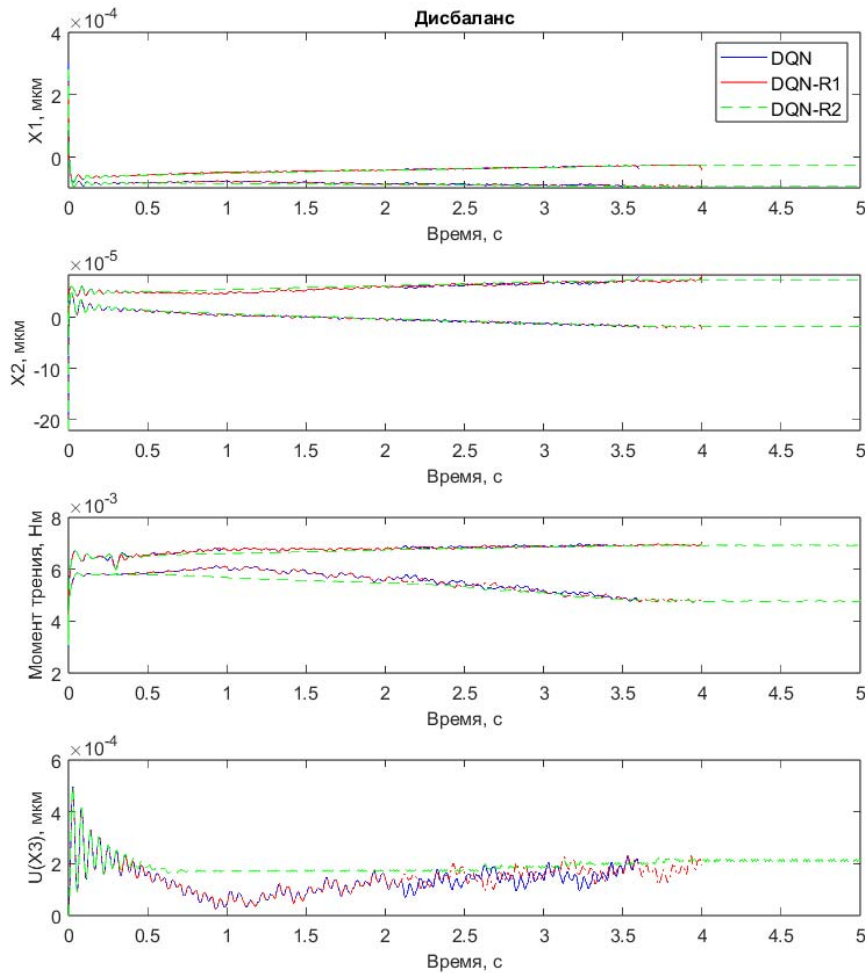


Рис. 6. Тестирование регуляторов при неопределенности внешнего воздействия

Вместе с тем, контроллеры на основе стандартного DQN подхода обеспечивают более быструю адаптацию системы к изменяющимся воздействиям и способность к превентивному реагированию на возможные воздействия, чем робастные DQN-R контроллеры.

Отмеченные различия позволяют в целом произвести разграничение сферы применения указанных методов. Так, стандартный DQN подход ввиду его отмеченных свойств может быть использован для контроллеров триботронных опор, где риск возникновения предельных нагрузок невелик, но важна способность к более быстрой адаптации режимов работы роторно-опорной системы. Потенциальной областью применения могут быть высокоскоростные роторные машины с постоянной или переменной частотой вращения и неравномерностью схем нагружения, например, турбокомпрессоры, турбодетандеры, газотурбинные установки и т.п. Робастное DQN-R управление, напротив, более целесообразно применять в системах, где изменения в параметрах системы и внешних воздействиях менее динамичны, но существует риск возникновения критических нагрузок и аварийного выхода из строя оборудования. Потенциальной областью применения могут служить высоконагруженные роторные машины, такие, как центрифуги, дробилки, опоры прокатных станов и т.п.

Заключение

Интеллектуальные контроллеры на базе методов обучения с подкреплением, в частности, глубокого нейросетевого Q-обучения с подкреплением (DQN), позволяют реализовывать в триботронных роторно-опорных системах комплексные стратегии оптимального управления, учитывающие сразу несколько целевых параметров. Так, для конической опоры с регулируемым осевым смещением втулки были синтезированы DQN-контроллеры, реализующие связанную минимизацию амплитуд перемещений цапфы в подшипнике и момента вязкого трения в смазочном слое. Кроме того, предложенный метод обучения DQN-контроллеров позволяет создавать регуляторы с робастными свойствами, обеспечивая устойчивость системы к неопределённостям её внутренних параметров и внешних воздействий. Синтезированные робастные DQN-R контроллеры в ходе численных экспериментов показали более устойчивую работу в таких условиях по сравнению с обычным DQN контроллером. Кроме того, робастность получаемых DQN-R контроллеров также зависит от величины неопределённости, учтённой в численной модели роторно-опорной системы при её обучении. Данные зависимости, как и метод синтеза робастных DQN-R контроллеров в целом, требует дальнейшего, более комплексного исследования, для установления его ключевых особенностей, возможностей и ограничений.

Исследование выполнено за счет гранта Российского научного фонда № 22-19-00789, <https://rscf.ru/project/22-19-00789/>.

Библиографический список

1. Santos I.F. Controllable sliding bearings and controllable lubrication principles – An overview // *Lubricants*. 2018. V. 6, Iss. 1. DOI: 10.3390/lubricants6010016
2. Santos I.F. Trends in controllable oil film bearings // *IUTAM Bookseries*. 2011. V. 25. P. 185-199. DOI: 10.1007/978-94-007-0020-8_17
3. Bently D.E., Grant J.W., Hanifan P.C. Active controlled hydrostatic bearings for a new generation of machines // *Proceedings of the ASME Turbo Expo (May, 8-11, 2000, Munich)*. 2000. V. 2. DOI: 10.1115/2000-GT-0354
4. Santos I.F., Nicoletti R., Scalabrin A. Feasibility of applying active lubrication to reduce vibration in industrial compressors // *Journal of Engineering for Gas Turbines and Power*. 2004. V. 126, Iss. 4. P. 848-854. DOI: 10.1115/1.1765123
5. Rehman W.U., Jiang G., Luo Y., Wang Y., Khan W., Rehman Sh.U., Iqbal N. Control of active lubrication for hydrostatic journal bearing by monitoring bearing clearance // *Advances in Mechanical Engineering*. 2018. V. 10, Iss. 4. DOI: 10.1177/1687814018768142
6. Rehman W.U., Luo Y., Wang Y., Jiang G., Iqbal N., Rehman Sh.U., Bibi Sh. Fuzzy logic-based intelligent control for hydrostatic journal bearing // *Measurement and Control*. 2019. V. 52, Iss. 3-4. P. 229-243. DOI: 10.1177/0020294019830110
7. Gupta S., Biswas P.K., Aljafari B., Thanikanti S.B., Das S.K. Modelling, simulation and performance comparison of different membership functions based fuzzy logic control for an active magnetic bearing system // *The Journal of Engineering*. 2023. V. 2023, Iss. 2. DOI: 10.1049/tje2.12229
8. Camino J.F., Santos I.F. A periodic linear-quadratic controller for suppressing rotor-blade vibration // *Journal of Vibration and Control*. 2019. V. 25, Iss. 17. P. 2351-2364. DOI: 10.1177/1077546319853358

9. Zhang G., Liu M., Zou H., Wang X., Xi G. Vibration control of a rotor-magnetic bearing system on the moving base through H_∞ control // Proceedings of the ASME Turbo Expo (June, 26-30, 2023, Boston). 2023. V. 11B. DOI: 10.1115/GT2023-102528
10. Li S., Babin A., Shutin D., Kazakov Yu., Liu Y., Chen Zh., Savin L. Active hybrid journal bearings with lubrication control: Towards machine learning // Tribology International. 2022. V. 175. DOI: 10.1016/j.triboint.2022.107805
11. Luo L., Zhao N., Zhu Y., Sun Y. A* guiding DQN algorithm for automated guided vehicle pathfinding problem of robotic mobile fulfillment systems // Computers & Industrial Engineering. 2023. V. 178. DOI: 10.1016/j.cie.2023.109112
12. Train DQN agent to swing up and balance pendulum. <https://www.mathworks.com/help/reinforcement-learning/ug/train-dqn-agent-to-swing-up-and-balance-pendulum.html>
13. Yu Y., Liu Y., Wang J., Noguchi N., He Y. Obstacle avoidance method based on double DQN for agricultural robots // Computers and Electronics in Agriculture. 2023. V. 204. DOI: 10.1016/j.compag.2022.107546
14. Kazakov Y.N., Kornaev A.V., Shutin D.V., Li Sh., Savin L.A. Active fluid-film bearing with deep q-network agent-based control system // Journal of Tribology. 2022. V. 144, Iss. 8. DOI: 10.1115/1.4053776
15. Kazakov Yu.N., Kornaev A.V., Shutin D.V., Kornaeva E.P., Savin L.A. Reducing rotor vibrations in active conical fluid film bearings with controllable gap // Russian Journal of Nonlinear Dynamics. 2022. V. 18, no. 5. P. 873-883. DOI: 10.20537/nd221226
16. Genkin M., McArthur J.J. A transfer learning approach to minimize reinforcement learning risks in energy optimization for automated and smart buildings // Energy and Buildings. 2024. V. 303. DOI: 10.1016/j.enbuild.2023.113760
17. Kitchat K., Lin M.-H., Chen H.-Sh., Sun M.T., Sakai K., Ku W.-Sh., Surasak T. A deep reinforcement learning system for the allocation of epidemic prevention materials based on DDPG // Expert Systems with Applications. 2024. V. 242. DOI: 10.1016/j.eswa.2023.122763
18. He X., Hu Zh., Yang H., Lv Ch. Personalized robotic control via constrained multi-objective reinforcement learning // Neurocomputing. 2024. V. 565. DOI: 10.1016/j.neucom.2023.126986
19. Baltes J., Christmann G., Saeedvand S. A deep reinforcement learning algorithm to control a two-wheeled scooter with a humanoid robot // Engineering Applications of Artificial Intelligence. 2023. V. 126. DOI: 10.1016/j.engappai.2023.106941
20. Deep Q-network agent. <https://www.mathworks.com/help/reinforcement-learning/ug/dqn-agents.html>
21. Antunovic R., Halep A., Bucko M., Peric S. Mathematical model for temperature change of a journal bearing // Thermal Science. 2018. V. 22, Iss. 1, Part A. P. 323-333. DOI: 10.2298/tsci160713109a
22. Kelly E., Amagbor A., Blessing T. Design and fabrication of a journal bearing test rig for pressure and temperature variation evaluation // NIPES Journal of Science and Technology Research. 2022. V. 4, Iss. 1. P. 234-243. DOI: 10.37933/nipes/4.1.2022.20
23. Савин Л.А., Соломин О.В. Моделирование роторных систем с опорами жидкостного трения. М.: Машиностроение-1, 2006. 443 с.
24. Sozinando D.F., Tchomeni B.X., Alugongo A.A. Experimental study of coupled torsional and lateral vibration of vertical rotor-to-stator contact in an inviscid fluid // Mathematical and Computational Applications. 2023. V. 28, Iss. 2. DOI: 10.3390/mca28020044

INTELLIGENT ROBUST CONTROLLERS FOR TRIBOTRONIC CONICAL FLUID FILM BEARINGS

© 2024

- Yu. N. Kazakov** Postgraduate Student of the Department of Mechatronics, Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
KazakYurii@yandex.ru
- D. V. Shutin** Candidate of Science (Engineering), Associate Professor of the Department of Mechatronics, Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
rover.ru@gmail.com
- L. A. Savin** Doctor of Science (Engineering), Professor of the Department of Mechatronics, Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
savin3257@mail.ru

The article presents the results of the development of means for intelligent robust control of the parameters of a tribotronic rotor-support system with a tapered bearing with a removable bush. The proposed controller is implemented on the basis of deep Q-network reinforcement learning (DQN) synthesized on the basis of a numerical model of a rotor support system. The control strategy involved simultaneous control of the shaft position and friction in the lubrication layer. Methods for control synthesis are presented for both a deterministic system and a system with stochastic parameters. In the latter case, a controller synthesis technique is proposed that takes into account uncertainties in the system at the training stage. Testing of the resulting controllers shows the better ability of a controller trained to take into account uncertainties to cope with variable loads, as well as predict possible changes in the system and proactively transfer the system to more advantageous states.

Tribotronic bearings; conical bearings; intelligent controllers; DQN; optimal control; robust control

Citation: Kazakov Yu.N., Shutin D.V., Savin L.A. Intelligent robust controllers for tribotronic conical fluid film bearings. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2024. V. 23, no. 3. P. 94-110.
DOI: 10.18287/2541-7533-2024-23-3-94-110

References

1. Santos I.F. Controllable sliding bearings and controllable lubrication principles – An overview. *Lubricants*. 2018. V. 6, Iss. 1. DOI: 10.3390/lubricants6010016
2. Santos I.F. Trends in controllable oil film bearings. *IUTAM Bookseries*. 2011. V. 25. P. 185-199. DOI: 10.1007/978-94-007-0020-8_17
3. Bently D.E., Grant J.W., Hanifan P.C. Active controlled hydrostatic bearings for a new generation of machines. *Proceedings of the ASME Turbo Expo (May, 8-11, 2000, Munich)*. 2000. V. 2. DOI: 10.1115/2000-GT-0354
4. Santos I.F., Nicoletti R., Scalabrin A. Feasibility of applying active lubrication to reduce vibration in industrial compressors. *Journal of Engineering for Gas Turbines and Power*. 2004. V. 126, Iss. 4. P. 848-854. DOI: 10.1115/1.1765123
5. Rehman W.U., Jiang G., Luo Y., Wang Y., Khan W., Rehman Sh.U., Iqbal N. Control of active lubrication for hydrostatic journal bearing by monitoring bearing clearance. *Advances in Mechanical Engineering*. 2018. V. 10, Iss. 4. DOI: 10.1177/1687814018768142
6. Rehman W.U., Luo Y., Wang Y., Jiang G., Iqbal N., Rehman Sh.U., Bibi Sh. Fuzzy logic-based intelligent control for hydrostatic journal bearing. *Measurement and Control*. 2019. V. 52, Iss. 3-4. P. 229-243. DOI: 10.1177/0020294019830110
7. Gupta S., Biswas P.K., Aljafari B., Thanikanti S.B., Das S.K. Modelling, simulation and performance comparison of different membership functions based fuzzy logic control for

an active magnetic bearing system. *The Journal of Engineering*. 2023. V. 2023, Iss. 2. DOI: 10.1049/tje2.12229

8. Camino J.F., Santos I.F. A periodic linear-quadratic controller for suppressing rotor-blade vibration. *Journal of Vibration and Control*. 2019. V. 25, Iss. 17. P. 2351-2364. DOI: 10.1177/1077546319853358

9. Zhang G., Liu M., Zou H., Wang X., Xi G. Vibration control of a rotor-magnetic bearing system on the moving base through H_∞ control. *Proceedings of the ASME Turbo Expo (June, 26-30, 2023, Boston)*. 2023. V. 11B. DOI: 10.1115/GT2023-102528

10. Li S., Babin A., Shutin D., Kazakov Yu., Liu Y., Chen Zh., Savin L. Active hybrid journal bearings with lubrication control: Towards machine learning. *Tribology International*. 2022. V. 175. DOI: 10.1016/j.triboint.2022.107805

11. Luo L., Zhao N., Zhu Y., Sun Y. A* guiding DQN algorithm for automated guided vehicle pathfinding problem of robotic mobile fulfillment systems. *Computers & Industrial Engineering*. 2023. V. 178. DOI: 10.1016/j.cie.2023.109112

12. Train DQN agent to swing up and balance pendulum. Available at: <https://www.mathworks.com/help/reinforcement-learning/ug/train-dqn-agent-to-swing-up-and-balance-pendulum.html>

13. Yu Y., Liu Y., Wang J., Noguchi N., He Y. Obstacle avoidance method based on double DQN for agricultural robots. *Computers and Electronics in Agriculture*. 2023. V. 204. DOI: 10.1016/j.compag.2022.107546

14. Kazakov Y.N., Kornaev A.V., Shutin D.V., Li Sh., Savin L.A. Active fluid-film bearing with deep q-network agent-based control system. *Journal of Tribology*. 2022. V. 144, Iss. 8. DOI: 10.1115/1.4053776

15. Kazakov Yu.N., Kornaev A.V., Shutin D.V., Kornaeva E.P., Savin L.A. Reducing rotor vibrations in active conical fluid film bearings with controllable gap. *Russian Journal of Nonlinear Dynamics*. 2022. V. 18, no. 5. P. 873-883. DOI: 10.20537/nd221226

16. Genkin M., McArthur J.J. A transfer learning approach to minimize reinforcement learning risks in energy optimization for automated and smart buildings. *Energy and Buildings*. 2024. V. 303. DOI: 10.1016/j.enbuild.2023.113760

17. Kitchat K., Lin M.-H., Chen H.-Sh., Sun M.T., Sakai K., Ku W.-Sh., Surasak T. A deep reinforcement learning system for the allocation of epidemic prevention materials based on DDPG. *Expert Systems with Applications*. 2024. V. 242. DOI: 10.1016/j.eswa.2023.122763

18. He X., Hu Zh., Yang H., Lv Ch. Personalized robotic control via constrained multi-objective reinforcement learning. *Neurocomputing*. 2024. V. 565. DOI: 10.1016/j.neucom.2023.126986

19. Baltes J., Christmann G., Saeedvand S. A deep reinforcement learning algorithm to control a two-wheeled scooter with a humanoid robot. *Engineering Applications of Artificial Intelligence*. 2023. V. 126. DOI: 10.1016/j.engappai.2023.106941

20. Deep Q-network agent. Available at: <https://www.mathworks.com/help/reinforcement-learning/ug/dqn-agents.html>

21. Antunovic R., Halep A., Bucko M., Peric S. Mathematical model for temperature change of a journal bearing. *Thermal Science*. 2018. V. 22, Iss. 1, Part A. P. 323-333. DOI: 10.2298/tsci160713109a

22. Kelly E., Amagbor A., Blessing T. Design and fabrication of a journal bearing test rig for pressure and temperature variation evaluation. *NIPES Journal of Science and Technology Research*. 2022. V. 4, Iss. 1. P. 234-243. DOI: 10.37933/nipes/4.1.2022.20

23. Savin L.A., Solomin O.V. *Modelirovanie rotornykh sistem s oporami zhidkostnogo treniya* [Modeling of rotor systems with fluid friction supports]. Moscow: Mashinostroenie-1 Publ., 2006. 443 p.

24. Sozinando D.F., Tchomeni B.X., Alugongo A.A. Experimental study of coupled torsional and lateral vibration of vertical rotor-to-stator contact in an inviscid fluid. *Mathematical and Computational Applications*. 2023. V. 28, Iss. 2. DOI: 10.3390/mca28020044