УДК 681.518:621.313.333

Исследование особенностей нейроуправления асинхронным двигателем с обучением в цифровом двойнике

А. Н. Марикин, А. М. Евстафьев, В. Г. Жемчугов, А. Д. Онофрийчук

Петербургский государственный университет путей сообщения Императора Александра I, Россия, 190031, Санкт-Петербург, Московский пр., 9

Для цитирования: *Марикин А. Н., Евстафьев А. М., Жемчугов В. Г., Онофрийчук А. Д.* Исследование особенностей нейроуправления асинхронным двигателем с обучением в цифровом двойнике // Известия Петербургского университета путей сообщения. СПб.: ПГУПС, 2026. Т. 23, вып. 3. С. 596–603. DOI: 10.20295/1815-588X-2026-3-596-603

Аннотация

Цель: исследование возможности прямого нейросетевого управления асинхронным электроприводом без предварительного задания полной математической модели двигателя и оценка влияния предлагаемого способа управления на потребляемую мощность при сохранении качества регулирования скорости на уровне, сопоставимом с классическим FOC. **Методы:** исследование выполнено на модели системы «инвертор — асинхронный двигатель — регулятор» в среде цифрового двойника. RL-агент обучали формировать управляющие воздействия в d-q-координатах, после чего результаты сопоставляли с FOC по среднеквадратичному току статора, активной мощности и ошибке регулирования скорости. **Практическая значимость:** полученная политика может быть перенесена на встроенную платформу управления электроприводом. Такой подход уменьшает зависимость качества регулирования от точности параметрической идентификации двигателя и поэтому представляет интерес для разработки энергоэффективных приводных систем.

Ключевые слова: асинхронный электродвигатель, электропривод, обучение с подкреплением, цифровой двойник, нейросетевое управление, векторное управление

Для асинхронного электропривода сохраняет актуальность задача одновременного обеспечения точного регулирования скорости, приемлемых динамических свойств и умеренного энергопотребления. На практике она, как правило, решается средствами векторного управления. Однако качество настройки FOC (Field-Oriented Control) в заметной степени зависит от параметров двигателя и условий его работы, поэтому при их изменении требуется дополнительная корректировка регуляторов [1, 2].

В связи с этим представляет интерес схема, в которой закон управления не задается заранее структурой регуляторов, а формируется в процессе обучения агента при взаимодействии с моделью привода. В такой постановке методы обучения с подкреплением позволяют искать управляющие воздействия по критерию, одновременно учитывающему ошибку регулирования и энергетические показатели [3, 4].

Научная новизна рассматриваемого решения связана с тем, что в структуре MIC (Motor Intelligent Control) RL-агент формирует воздействия на инвертор непосредственно в d-q-координатах без использования стандартного каскада PI-регуляторов по току. Обучение проводится в среде цифрового двойника, что позволяет без риска выполнять большое число эпизодов и подбирать стратегию по заданному критерию качества. После обучения политика

упрощается для последующей реализации на встроенной платформе. Тем самым в одной схеме сочетаются обучение в модели, прямое управление приводом и перенос полученной политики на микроконтроллер.

Применение алгоритмов обучения с подкреплением непосредственно для управления асинхронным электродвигателем — относительно новый шаг в силовой электронике и электроприводах. В традиционных системах управления, чтобы учесть нелинейности и неопределенности, часто используют сложные наблюдатели или адаптивные контуры. Смежный подход DeepMPC использует обучаемую модель динамики в предиктивном контуре [5]. Агент обучается правильным действиям методом проб и ошибок, получая вознаграждение за достижение целей управления [4]. Это устраняет необходимость настройки регуляторов на основе модели и повышает динамическую адаптивность к изменяющимся условиям.

Цель работы состоит в оценке возможности обеспечения прямого нейросетевого управления асинхронным электроприводом для снижения потребления активной мощности по сравнению с FOC без заметного ухудшения качества регулирования скорости. Для этого RL-агент обучали в среде цифрового двойника, после чего анализировали устойчивость сформированной стратегии в типовых режимах и сопоставляли полученные результаты с базовым вариантом векторного управления. Такая постановка позволяет судить о практической применимости метода еще до перехода к физическому стенду.

На рис. 1 показан переход MIC (Motor Intelligent Control) от разработки к эксплуатации.

Этап 1 (модельный). MIC обучается в среде математической модели АД на наборе режимов и разбросе параметров. Цель этапа — получить устойчивую стартовую политику и отладить процедуру обучения без риска для оборудования, обеспечив переносимость на разные двигатели.

Этап 2 (перенос на стенд). MIC переносится на реальный привод (АИН-АД), и выполняется ускоренная адаптация под конкретный двигатель с использованием БЭК (бесконтактного энкодера) как источника обратной связи и средства контроля качества. Цель этапа —

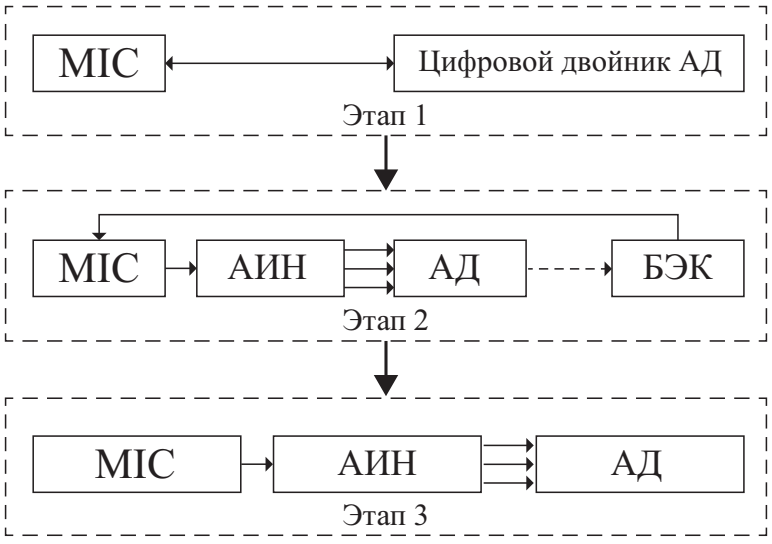


Рис. 1. Схема обучения алгоритма MIC

быстро подстроить политику к реальным нелинейностям, потерям, насыщению и задержкам, минимизируя число экспериментов.

Этап 3 (эксплуатация без БЭК). Обучение отключается, энкодер выводится из контура, и MIC управляет АИН без обратной связи по скорости, используя выученный закон управления [6]. Цель этапа — обеспечить работу привода без датчика скорости и снизить требования к измерительной части при сохранении заданного качества управления. В отличие от классической иерархии (скорость — ток — напряжение), здесь нейросеть решает задачу оптимального управления за один шаг.

Прямое обучение на реальном стенде на начальном этапе работы представляется нецелесообразным, поскольку большое число пробных воздействий повышает вероятность аварийных режимов и существенно увеличивает время отладки. Поэтому агент обучался на цифровом двойнике асинхронного двигателя. В этой среде многократно воспроизводились разгон, торможение и установившиеся режимы без риска для оборудования. Функция вознаграждения задавалась по двум основным признакам: ошибке по скорости и уровню потребляемой мощности. Тем самым агент настраивался не только на достижение требуемой скорости, но и на выбор более экономичного режима работы. Использование цифрового двойника позволило рассмотреть большое число эпизодов и получить стратегию, в которой динамические и энергетические требования учитываются одновременно.

Цифровой двойник использовался не только как безопасная среда обучения, но и как инструмент оценки чувствительности алгоритма к изменению параметров привода. В модели варьировали нагрузку, момент инерции и параметры двигателя, после чего проверяли, сохраняется ли работоспособность обученной политики. При переносе алгоритма с модели на физический объект необходимо учитывать эффект sim-to-real, то есть возможное расхождение между поведением цифрового двойника и реального привода. Для уменьшения этого расхождения целесообразно вводить случайный разброс параметров уже на этапе обучения. В таком случае агент взаимодействует не с единственным вариантом модели, а с семейством близких режимов, что обычно повышает устойчивость его поведения при переходе к реальному объекту [7–9].

Для обучения агента использовались современные алгоритмы глубокого RL, предназначенные для задач с непрерывным пространством действий, в частности применялись методы Twin Delayed DDPG (TD3) и сравнительно Proximal Policy Optimization (PPO). Эти алгоритмы на каждом шаге симуляции обновляют параметры нейросети агента, стремясь увеличить суммарное дисконтированное вознаграждение за эпизод. Обучение проводилось онлайн: агент взаимодействовал с цифровым двойником в ходе множества эпизодов, постепенно улучшая стратегии.

Эпизоды моделировали стандартные рабочие циклы привода: разгон до требуемой скорости, удержание нагрузки, торможение. По мере накопления опыта агент уменьшал ошибку слежения за скоростью и энергопотребление, приближаясь к оптимальной политике по заданному критерию.

После завершения обучения полученную политику необходимо согласовать с вычислительными ограничениями встроенной платформы. Исходная модель агента, обученная в симуляции, содержит слишком большое число параметров для устойчивого выполнения в реальном времени на микроконтроллере. Поэтому на следующем этапе использовалась дистилляция: компактную сеть обучали

воспроизводить действия исходного агента на тех же входных состояниях [10]. Такой прием позволяет уменьшить размер модели без существенной потери качества управления. В итоге формируется облегченная политика, пригодная для исполнения на встроенном устройстве и сохраняющая основные особенности поведения исходного агента.

Обучение проводится офлайн на более мощном вычислителе, но итоговая инференс-модель приводится к форме, пригодной для микроконтроллера. Такой подход обеспечивает автономность системы MIC: после этапа лабораторного обучения интеллектуальный контроллер можно загрузить во встроенный блок управления привода и эксплуатировать подобно обычному частотному преобразователю, без постоянного подключения к внешнему компьютеру.

В системе MIC управление асинхронным электроприводом реализуется на основе нейросетевого алгоритма обучения с подкреплением, выполняющего функцию основного регулятора. Обучение алгоритма проводится в виртуальной среде, включающей цифровой двойник асинхронного двигателя и модель силового инвертора. В процессе обучения RL-агент взаимодействует с математической моделью привода, получая измеряемые параметры состояния, в частности скорость вращения и токи статора, и формируя управляющие воздействия для инвертора. Качество управления оценивается по точности регулирования скорости и энергетической эффективности режима. В результате многократных эпизодов обучения агент формирует стратегию управления, обеспечивающую компромисс между динамическими и энергетическими показателями без использования априорной математической модели двигателя.

После завершения этапа обучения нейросетевая модель подвергается процедурам оптимизации и сжатия и может быть реализована в виде компактного контроллера, предназначенного для работы на встроенной вычислительной платформе. В режиме эксплуатации контроллер использует измеряемые сигналы привода для формирования управляющих воздействий на силовой инвертор, при этом структура силовой части и стандартные защитные функции сохраняются. Существенной особенностью предлагаемого подхода является то, что ограничения по токам и режимам работы учитываются не внешними ограничителями, а заложены непосредственно в стратегию управления, сформированную в процессе обучения.

Для оценки поведения алгоритма MIC выполнена серия численных экспериментов на цифровом двойнике асинхронного электродвигателя в режиме ступенчатого изменения нагрузки. В качестве базового метода сравнения использовалось классическое векторное управление (FOC) с PI-регуляторами. Эксперименты проводились в двух режимах (рис. 3): стадия 0 соответствовала нагрузке $0{,}5M_{\text{ном}}$, а стадия 1 — нагрузке $1{,}0M_{\text{ном}}$. В качестве критериев оценки рассматривались среднеквадратичный ток статора, средняя потребляемая активная электрическая мощность асинхронного двигателя и средняя абсолютная ошибка регулирования скорости.

Энергетический эффект применения MIC оценивали по временной зависимости активной мощности и сопоставляли с результатами, полученными для FOC. В переходном процессе различие между кривыми оставалось небольшим, однако после выхода в установившийся режим зависимость для MIC располагалась ниже, чем для FOC. На выбранном интервале усреднения снижение активной мощности составило 8,4 %. Этот результат согласуется с уменьшением среднеквадратичного тока статора и показывает, что выигрыш по энергии достигается не за счет ухудшения регулирования скорости,

а вследствие более экономичного режима работы привода в установившемся состоянии.

На рис. 3 представлены рабочие характеристики привода АИР-56 при управлении FOC и MIC.

Сопоставление рабочих характеристик показывает, что после этапа адаптивного обучения регулятор MIC воспроизводит зависимости, качественно согласующиеся с характеристиками эталонного FOC во всем исследованном диапазоне нагрузок. В области, близкой к максимальной нагрузке, наблюдается устойчивый энергетический эффект: при управлении MIC входная мощность несколько ниже, а КПД

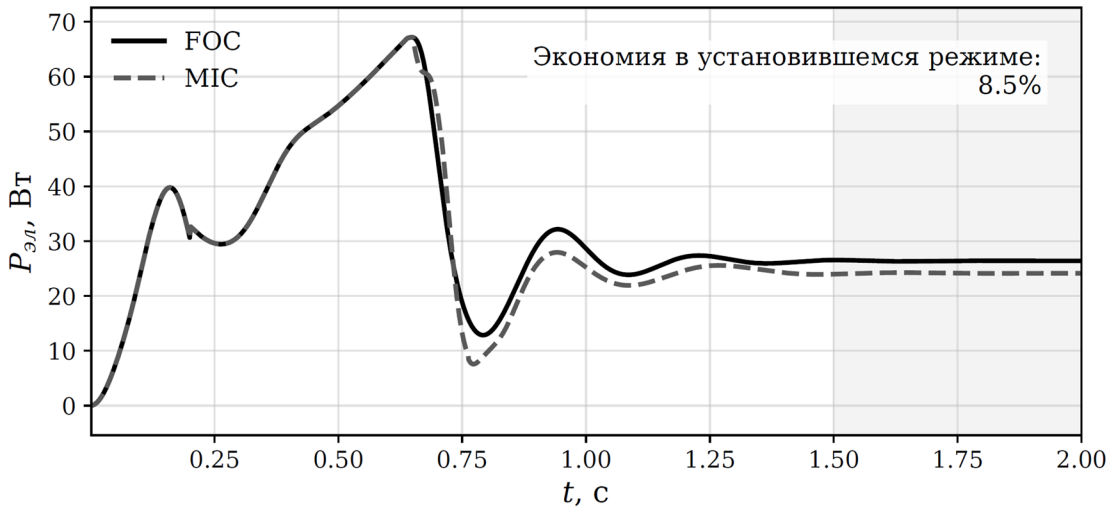


Рис. 2. Сравнение потребляемой электрической мощности электропривода при управлении FOC и MIC

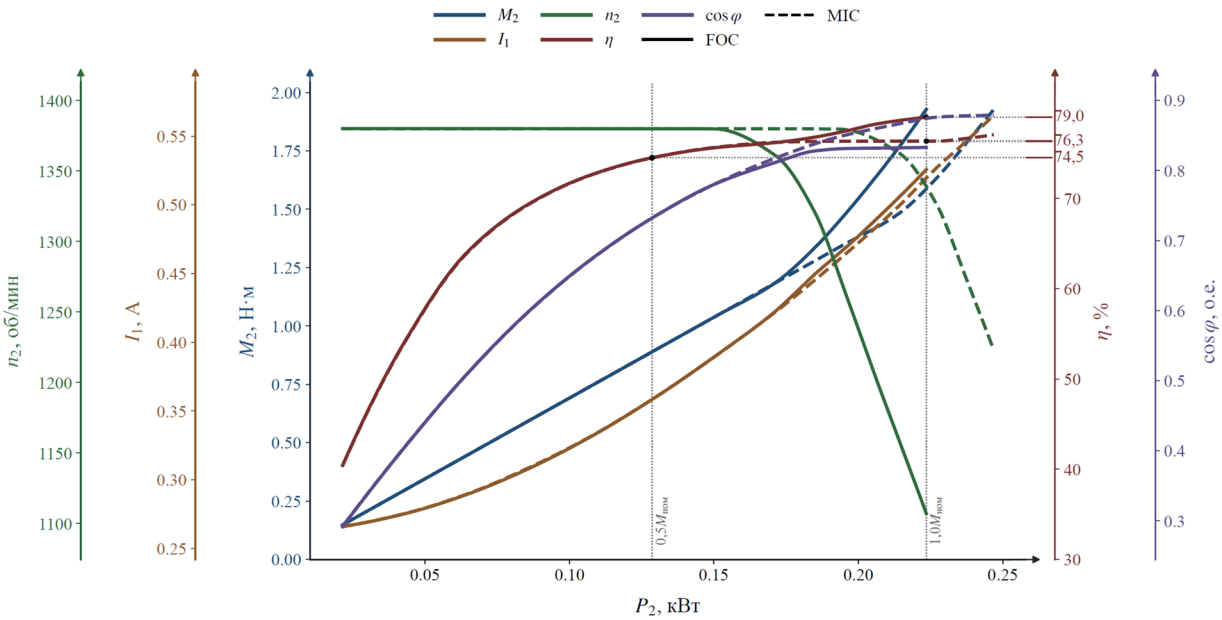


Рис. 3. Рабочие характеристики асинхронного двигателя

несколько выше, чем при FOC. Наиболее заметно это проявляется в высоконагруженном режиме, где энергетические потери максимальны. При этом форма механических характеристик остается физически корректной: с ростом нагрузки момент и ток возрастают монотонно, а скорость уменьшается контролируемым образом. Настройка регулятора выполнялась без предварительной идентификации полного набора параметров двигателя; обучение велось по измеряемым сигналам, что указывает на устойчивость сформированной стратегии управления. Следовательно, даже при неопределенности параметров объекта MIC обеспечивает качество регулирования, сопоставимое с FOC, и одновременно демонстрирует устойчиво воспроизводимый энергетический выигрыш в области высоких нагрузок. Дополнительной особенностью подхода является отсутствие каких-либо устройств на роторе двигателя.

По результатам моделирования могут быть сформулированы следующие выводы:

1. В структуре MIC управляющие воздействия формируются RL-агентом непосредственно в d-q-координатах, без каскада PI-регуляторов по току. Обучение проводилось в среде цифрового двойника, что позволило отработать стратегию управления без предварительной настройки полной параметрической модели двигателя.

2. В обеих исследованных стадиях для MIC получено снижение среднеквадратичного тока статора по сравнению с FOC. Это указывает на менее нагруженный режим работы двигателя при сохранении требуемого режима регулирования.

3. Средняя активная мощность в режиме MIC оказалась ниже, чем при FOC. На интервале установившегося режима снижение составило 8,4 %, поэтому речь идет не только о визуальном расхождении кривых, но и о количественно подтверждаемом энергетическом эффекте.

4. По качеству регулирования скорости MIC не уступал базовому варианту FOC, а в отдельных режимах показывал меньшую среднюю абсолютную ошибку. Следовательно, снижение потребляемой мощности не сопровождалось заметным ухудшением динамических свойств привода.

5. Полученные данные показывают, что выбранная функция вознаграждения действительно смещает стратегию агента к компромиссу между точностью регулирования и энергопотреблением.

Таким образом, результаты моделирования подтверждают работоспособность подхода и позволяют перейти к следующему этапу, связанному с переносом упрощенной нейросетевой политики на реальный стенд и ее последующей экспериментальной проверкой.

Список источников

1. Kazemikia D. Reinforcement Learning for Motor Control: a Comprehensive Review // arXiv preprint. 2024. URL: https://arxiv.org/abs/2412.17936 (дата обращения: 15.12.2025).

2. Field-Oriented Control of PMSM Using Reinforcement Learning // MathWorks Motor Control Blockset Example. URL: https://www.mathworks.com/help/mcb/gs/foc-of-pmsm-using-reinforcement-learning.html (дата обращения: 15.12.2025).

3. AI-Based Field-Oriented Control for Induction Motors / E. Benmalek [et al.] // IAPGOS. 2024. Vol. 14, № 4. Pp. 75–81. URL: https://doi.org/10.35784/iapgos.6253 (дата обращения: 15.12.2025).

4. Enhanced Induction Motor Control Using Deep Reinforcement Learning and PWM with DTC / P. Saurabh [et al.] // Electric Power Components and Systems. 2023. Vol. 51, no. 12. Pp. 1083–1095. URL: https://doi.org/10.1080/15325008.2023.2274357 (дата обращения: 15.12.2025).

5. Lenz I., Knepper R., Saxena A. DeepMPC: Learning Deep Latent Features for Model Predictive Control // Proc. of Robotics: Science and Systems. 2015. URL: https://doi.org/10.15607/RSS.2015.XI.012 (дата обращения: 15.12.2025).

6. Sensorless Speed Control of Induction Motor Drives Using Reinforcement Learning and Self-Tuning Simplified Fuzzy Logic Controller / Q. Abdullah [et al.] // IEEE Access. 2024. Vol. 12. Pp. 136485–136501. URL: https://doi.org/10.1109/ACCESS.2024.3435529 (дата обращения: 15.12.2025).

7. Eschmann J., Albani D., Loianno G. RLtools: A Fast, Portable Deep Reinforcement Learning Library for Continuous Control // Journal of Machine Learning Research. 2024. Vol. 25, no. 301. Pp. 1–19. URL: https://www.jmlr.org/papers/v25/24-0248.html (дата обращения: 15.12.2025).

8. TinyRL: Towards Reinforcement Learning on Tiny Embedded Devices / T. Szydlo [et al.] // Proc. of the 31st ACM Int. Conf. on Information and Knowledge Management (CIKM). 2022. Pp. 4985–4988. URL: https://doi.org/10.1145/3511808.3557206 (дата обращения: 15.12.2025).

9. Enhancing Field-Oriented Control of Electric Drives with Tiny Neural Network Optimized for Microcontrollers / M. J. Mouk Elele [et al.] // arXiv preprint. 2025. URL: https://arxiv.org/abs/2502.00532 (дата обращения: 15.12.2025).

10. A Survey of Reinforcement Learning-Driven Knowledge Distillation: Techniques, Challenges, and Applications / Z. Xu [et al.] // Preprints. 2025. URL: https://doi.org/10.20944/preprints202503.0903.v2 (дата обращения: 15.12.2025).

Дата поступления: 13.05.2026
Решение о публикации: 07.07.2026

Контактная информация:
МАРИКИН Александр Николаевич — доктор техн. наук, профессор; marikin_s@mail.ru
ЕВСТАФЬЕВ Андрей Михайлович — доктор техн. наук, профессор; evstam@mail.ru
ЖЕМЧУГОВ Валерий Григорьевич — кандидат техн. наук, доцент, zhemchugov@pgups.ru
ОНОФРИЙЧУК Андрей Дмитриевич – аспирант, 11lisov11@gmail.com

Study of Direct Neural Control of an Induction Motor Trained in a Digital Twin

A. N. Marikin, A. M. Evstaf'ev, V. G. Zhemchugov, A. D. Onofrijchuk

Emperor Alexander I Petersburg State Transport University, 9 Moskovsky ave., St. Petersburg, 190031, Russia

For citation: *Marikin A. N., Evstaf'ev A. M., Zhemchugov V. G., Onofriychuk A. D.* Study of Direct Neural Control of an Induction Motor Trained in a Digital Twin // Proceedings of Petersburg State Transport University, 2026. Vol. 23, iss. 3. Pp. 596–603. DOI: 10.20295/1815-588X-2026-3-596-603 (In Russian)

Abstract

Objective: to assess the feasibility of direct neural control of an induction motor drive without a fully specified mathematical model of the motor and to determine whether this approach can reduce active power consumption while maintaining speed-control quality comparable to classical field-oriented control. **Methods:** the study was carried out on a digital-twin model of the inverter-induction motor-controller system. A reinforcement learning agent was trained to generate control actions in the d-q reference frame, and its performance was compared with FOC using the stator RMS current, active power, and speed-control

error as evaluation criteria. **Practical significance:** the trained policy can potentially be transferred to an embedded drive-control platform. This reduces the dependence of control quality on accurate parameter identification and makes the approach relevant for energy-efficient electric drives.

Keywords: induction motor, electric drive, reinforcement learning, digital twin, neural network control, field-oriented control

References

1. Kazemikia D. Reinforcement Learning for Motor Control: A Comprehensive Review, arXiv preprint, 2024. URL: https://arxiv.org/abs/2412.17936 (accessed: December 15, 2025)

2. Field-Oriented Control of PMSM Using Reinforcement Learning, MathWorks Motor Control Blockset Example. URL: https://www.mathworks.com/help/mcb/gs/foc-of-pmsm-using-reinforcement-learning.html (accessed: December 15, 2025)

3. Benmalek E., et al. AI-Based Field-Oriented Control for Induction Motors, IAPGOS, 2024, vol. 14, no. 4, pp. 75–81. URL: https://doi.org/10.35784/iapgos.6253 (accessed: December 15, 2025)

4. Saurabh P., et al. Enhanced Induction Motor Control Using Deep Reinforcement Learning and PWM with DTC, Electric Power Components and Systems, 2023, vol. 51, no. 12, pp. 1083–1095. URL: https://doi.org/10.1080/15325008.2023.2274357 (accessed: December 15, 2025)

5. Lenz I., Knepper R., Saxena A. DeepMPC: Learning Deep Latent Features for Model Predictive Control, Proceedings of Robotics: Science and Systems, 2015. URL: https://doi.org/10.15607/RSS.2015.XI.012 (accessed: December 15, 2025).

6. Abdullah Q., et al. Sensorless Speed Control of Induction Motor Drives Using Reinforcement Learning and Self Tuning Simplified Fuzzy Logic Controller, IEEE Access, 2024, vol. 12, pp. 136 485–136 501. URL: https://doi.org/10.1109/ACCESS.2024.3435529 (accessed: December 15, 2025).

7. Eschmann J., Albani D., Loianno G. RLtools: A Fast, Portable Deep Reinforcement Learning Library for Continuous Control, Journal of Machine Learning Research, 2024, vol. 25, no. 301, pp. 1–19. URL: https://www.jmlr.org/papers/v25/24-0248.html (accessed: December 15, 2025).

8. Szydlo T., et al. TinyRL: Towards Reinforcement Learning on Tiny Embedded Devices, Proceedings of the 31st ACM International Conference on Information and Knowledge Management (CIKM), 2022, pp. 4985–4988. URL: https://doi.org/10.1145/3511808.3557206 (accessed: December 15, 2025).

9. Mouk Elele M. J., et al. Enhancing Field-Oriented Control of Electric Drives with Tiny Neural Network Optimized for Microcontrollers, arXiv preprint, 2025. URL: https://arxiv.org/abs/2502.00532 (accessed: December 15, 2025).

10. Xu Z., et al. A Survey of Reinforcement Learning Driven Knowledge Distillation: Techniques, Challenges, and Applications, Preprints, 2025. URL: https://doi.org/10.20944/preprints202503.0903.v2 (accessed: December 15, 2025).

Received: May 13, 2026
Accepted: July 07, 2026

Author's information:
Aleksandr N. MARIKIN — Dr. Sci. in Engineering, Professor; marikin_s@mail.ru
Andrej M. EVSTAF'EV — Dr. Sci. in Engineering, Professor; evstam@mail.ru
Valerij G. ZHEMCHUGOV — PhD in Engineering, Associate Professor; zhemchugov@pgups.ru
Andrej D. ONOFRIJCHUK — Postgraduate Student; 11lisov11@gmail.com