

**СТРУКТУРНЫЙ И ПАРАМЕТРИЧЕСКИЙ СИНТЕЗ НЕЙРОСЕТЕВОГО ЭМУЛЯТОРА ДИНАМИКИ
АВТОНОМНОГО НЕОБИТАЕМОГО ПОДВОДНОГО АППАРАТА**

А. Н. Борисов*, М. А. Борисова, Ю. Л. Сиек

Санкт-Петербургский государственный морской технический университет, Санкт-Петербург, Россия

* bor_fond93@mail.ru

Аннотация. В настоящее время перед разработчиками информационно-управляющих систем морской подводной техники открываются новые возможности применения современных высокопроизводительных технологий для повышения качества процессов управления и точности выполнения операций. Так, например, для обеспечения синтеза алгоритмов управления движением активно исследуются подходы на основе прогнозирующих моделей (ПМ). При этом для синтеза ПМ могут применяться современные методы машинного обучения, в том числе — искусственные нейронные сети (ИНС). Предложен способ построения ПМ в составе алгоритмического обеспечения информационно-управляющих систем автономного необитаемого подводного аппарата с использованием нейросетевого эмулятора динамики. Проанализированы основные недостатки традиционного подхода к синтезу ПМ в виде системы дифференциальных уравнений, выполнен последовательный структурный и параметрический синтез нейроэмулятора. В частности, рассмотрены вопросы начальной инициализации параметров нейронной сети и формирования обучающей выборки, определена структура входных и выходных данных. Особенностью предлагаемой структуры ИНС является использование предобучения на основе каскада автоэнкодеров. Приведены результаты предобучения нейросетевого эмулятора, обосновывающие выбор архитектуры ИНС. Также для проверки адекватности ПМ в виде нейроэмулятора выполнена верификация относительно известной нелинейной динамической модели в ходе статистического имитационного моделирования.

Ключевые слова: АНПА, нейроэмулятор, глубокое обучение, предобучение, автоэнкодеры

Ссылка для цитирования: Борисов А. Н., Борисова М. А., Сиек Ю. Л. Структурный и параметрический синтез нейросетевого эмулятора динамики автономного необитаемого подводного аппарата // Изв. вузов. Приборостроение. 2025. Т. 68, № 1. С. 5–12. DOI: 10.17586/0021-3454-2025-68-1-5-12.

**STRUCTURAL AND PARAMETRIC SYNTHESIS OF A NEURAL NETWORK EMULATOR
OF AN AUTONOMOUS UNMANNED UNDERWATER VEHICLE DYNAMICS**

A. N. Borisov*, M. A. Borisova, Yu. L. Siek

State Marine Technical University, St. Petersburg, Russia

* bor_fond93@mail.ru

Abstract. Currently, developers of information and control systems for marine underwater equipment are faced with new opportunities for using modern high-performance technologies to improve the quality of control processes and the accuracy of operations. For example, approaches based on predictive models (PM) are actively studied to ensure the synthesis of motion control algorithms. In this case, modern machine learning methods, including artificial neural networks (ANN), can be used to synthesize PM. A method for constructing a PM as part of the algorithmic support of information and control systems of an autonomous unmanned underwater vehicle using a neural network emulator of dynamics is proposed. The main disadvantages of the traditional approach to the synthesis of PM in the form of a system of differential equations are analyzed, a sequential structural and parametric synthesis of the neural emulator is performed. In particular, the issues of initial initialization of the neural network parameters and the formation of a training sample are considered,

the structure of input and output data is determined. A feature of the proposed ANN structure is the use of pretraining based on a cascade of autoencoders. Results of pretraining the neural network emulator are presented, justifying the choice of the ANN architecture. Also, to check the adequacy of the PM in the form of a neuroemulator, verification is performed with respect to a known nonlinear dynamic model during statistical simulation modeling.

Keywords: AUV, neural network emulator, deep learning, pretraining, autoencoder

For citation: Borisov A. N., Borisova M. A., Siek Yu. L. Structural and parametric synthesis of a neural network emulator of an autonomous unmanned underwater vehicle dynamics. *Journal of Instrument Engineering*. 2025. Vol. 68, N 1. P. 5–12 (in Russian). DOI: 10.17586/0021-3454-2025-68-1-5-12.

Введение. Актуальным способом построения информационно-управляющих систем (ИУС) динамических объектов, в том числе автономных необитаемых подводных аппаратов (АНПА) [1], является применение прогнозирующих моделей, или MPC (Model Predictive Control) [2–4]. Недостатком ИУС с прогнозирующей моделью (ПМ) является высокая вычислительная сложность [5]. Для вычисления управляющих сигналов на каждом такте работы решается оптимизационная задача путем многократного интегрирования системы дифференциальных уравнений, описывающих динамику АНПА. При этом в системе уравнений не учитываются различные внешние возмущения, что негативно влияет на точность прогноза. В работе [6] предложен метод повышения вычислительной эффективности за счет использования параллельных вычислительных технологий, однако это не снижает сложности задачи. Также качество процессов управления во многом определяется используемой для прогноза математической моделью АНПА [7], а следовательно, и точностью идентификации ее параметров [8].

Рассмотренные недостатки приводят к необходимости разработки способов снижения вычислительной сложности алгоритмического обеспечения ИУС с сохранением уровня адекватности прогнозирующей модели. Для этого могут применяться искусственные нейронные сети [9, 10]. Настоящая статья посвящена структурному и параметрическому синтезу искусственной нейронной сети, выступающей в качестве прогнозирующей модели динамики АНПА.

Постановка задачи синтеза нейросетевого эмулятора. Нейронные сети, благодаря своим аппроксимирующим свойствам, используются в качестве модели для представления динамики АНПА. В то время как при аналитическом описании нелинейной динамической модели (НДМ) с помощью дифференциальных уравнений используются глубинные знания о системе на основе фундаментальных законов физики, в нейросетевом моделировании объект рассматривается в качестве „черного ящика“, входные и выходные сигналы которого известны. Задача такой нейросетевой модели, называемой также нейроэмулятором (НЭ) системы, состоит в подражании поведению этого „черного ящика“. При аналитическом описании объекта управления необходимо определить некоторые параметры, такие как гидродинамические коэффициенты, присоединенные массы жидкости, моменты инерции [8]. Для нейросетевой модели требуются определение общей архитектуры ИНС, а также подстройка коэффициентов нейронных связей, выполняемая в процессе обучения. При синтезе НЭ исследуемый АНПА или его математическая модель используется для генерирования обучающей выборки, размер которой определяет точность ИНС.

Нейроэмулятор или нейросетевой предиктор получает на вход информацию о состоянии объекта управления $x(t_k)$, а также управляющих сигналах $\tau(t_k)$ в момент времени t_k , и позволяет спрогнозировать состояние на один такт работы ИУС вперед $x(t_{k+1})$. Ошибка прогноза δ используется в методе обратного распространения ошибки при обучении ИНС. Поскольку на вход нейроэмулятора может подаваться информация с выхода ИНС, то прогноз работы возможен и на несколько тактов вперед, однако в таком случае возрастает ошибка прогнозирования. Таким образом, нейроэмулятор (рис. 1, б) от нейропредиктора (а) отличается наличием обратной связи по текущему вектору состояния.

Практическая реализация нейроэмулятора возможна, если структура ИНС соответствует сложности объекта управления. Высокая сложность динамических моделей АНПА обуславливает необходимость использования глубоких нейронных сетей, особенностью которых является

использование нескольких скрытых слоев. Таким образом, в настоящей статье рассматривается задача структурного и параметрического синтеза ИНС для прогнозирования динамических параметров движения АНПА в вертикальной плоскости.




Рис. 1

Структурный и параметрический синтез нейроэмулятора. Для прогнозирования динамики АНПА ИНС вычисляет отображение входного вектора состояния в момент времени t_k — $x(t_k)$ и вектора управления $\tau(t_k)$ в выходной вектор состояния $x^*(t_{k+1}) = \varphi(x(t_k), \tau(t_k), W)$. При этом на основе обучающей выборки происходит обучение параметров нейронных связей (весовых коэффициентов) W , что приводит к наилучшей аппроксимации φ с целью минимизации используемой функции потерь. Особенности градиентных методов обучения ИНС обуславливают важность выбора стратегии начальной инициализации W .

Современные стратегии инициализации весовых коэффициентов носят эвристический характер. Большинство способов инициализации имеет целью придать нейроэмулятору некоторый набор свойств в начальной стадии обучения. Однако нет строгого доказательства того, что эти свойства будут сохранены в процессе обучения и каким-либо образом повлияют на процесс тренировки нейронной сети.

Распространенным подходом к обучению глубоких нейронных сетей является инициализация весовых коэффициентов модели значениями, взятыми случайным образом из гауссова или равномерного распределения. Однако параметры начального распределения оказывают большое влияние как на результат процедуры оптимизации, так и на способность сети к обобщению.

В работе [11] показано, что параметры распределения для инициализации весовых коэффициентов также зависят от типа активационной функции в слое. При использовании сигмоидальной или тангенциальной функции активации используется метод Ксавьера:

$$W^{[l][i]} = U \left[-\sqrt{\frac{1}{n}}, \sqrt{\frac{1}{n}} \right], \quad (1)$$

где $W^{[l][i]}$ — весовой коэффициент нейронной связи i в слое l , n — число нейронов в предыдущем слое, U — случайное равномерно распределенное число.

В работе [12] показано, что при использовании функций активации вида ReLU наиболее подходящим способом является инициализация:

$$W^{[l][i]} = U \left[-\sqrt{\frac{2}{n}}, \sqrt{\frac{2}{n}} \right]. \quad (2)$$

В настоящее время многие исследователи отмечают эффективность инициализации параметров сети, основанной на предобучении ИНС [13]. Для этого процедура тренировки сети разбивается на два этапа. На первом этапе послойно обучается автоассоциативная сеть (автоэнкодер), после чего полученными весовыми коэффициентами скрытых слоев автоассоциативной сети инициализируются нейроны скрытых слоев нейроэмулятора. На рис. 2 схематично показан

процесс обучения и переноса параметров сети (h_i — номер скрытого слоя). После обучения первого автоэнкодера выходные значения нейронов скрытого слоя становятся входами второго и так далее.

Обучающая выборка формируется на основе вычисленных согласно известной имитационной модели [14] прогнозных значений вектора состояния на следующем такте работы ИУС (выходной вектор) по текущим элементам вектора состояния и управления (входной вектор). Стоит отметить, что в случае использования для обучения нейроэмулятора экспериментальных траекторных данных в качестве входных и выходных векторов будут использоваться измеренные элементы вектора состояния. Таким образом, нейроэмулятор на основе конечного множества примеров переходов состояний объекта управления учится формировать прогноз на потенциально бесконечном множестве значений входных аргументов.

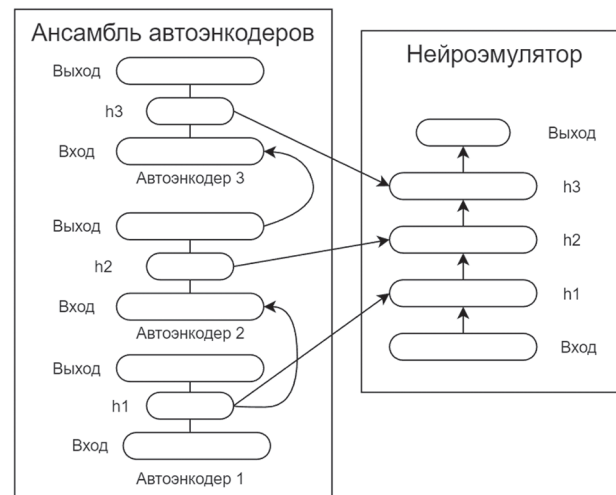


Рис. 2

В работе рассматривается управляемое движение АНПА в вертикальной плоскости. Подробная математическая модель представлена в работе [7]. Внешний облик АНПА и используемые системы координат (СК) представлены на рис. 3. Здесь $O_3\xi\eta\epsilon$ — инерциальная условно неподвижная СК; $Oxyz$ — связанная с корпусом СК; T — тяга маршевого движителя; $T_k(\tau)$ и $T_n(\tau)$ — тяги кормового и носового подруливающих движителей, зависящие от сигнала управления τ .




Рис. 3

Входным вектором в момент времени t_k является $\mathbf{x}_B = [V_x(t_k) \ V_y(t_k) \ \omega_z(t_k) \ \theta(t_k) \ \tau(t_k)]^T$, где V_x, V_y — линейные скорости объекта управления, ω_z — угловая скорость вращения, θ — угол дифферента, τ — управляющий сигнал. Обобщенная структура нейроэмулятора представлена на рис. 4.

В табл. 1 показаны области допустимых значений для формирования комбинированной сетки обучающего набора данных нейроэмулятора движения в вертикальной плоскости. Пределы изменения кинематических параметров получены исходя из результатов анализа траекторных данных имитационного моделирования управляемого движения АНПА типа „Арктика“ [15]. Выходные значения нейронной сети для обучающей выборки, в соответствии с имитационной моделью АНПА типа „Арктика“, вычисляются по следующим пределам допустимых значений: $V_x = 0\text{--}2$ м/с (шаг сетки 15); $V_y = -0,1391\text{--}0,1391$ м/с (шаг сетки 10); $\omega_z = -0,05\text{--}0,05$ рад/с (шаг сетки 15); $\theta = -0,28\text{--}0,28$ рад (шаг сетки 30); $\tau = -100\text{--}100$ Н (шаг сетки 60).

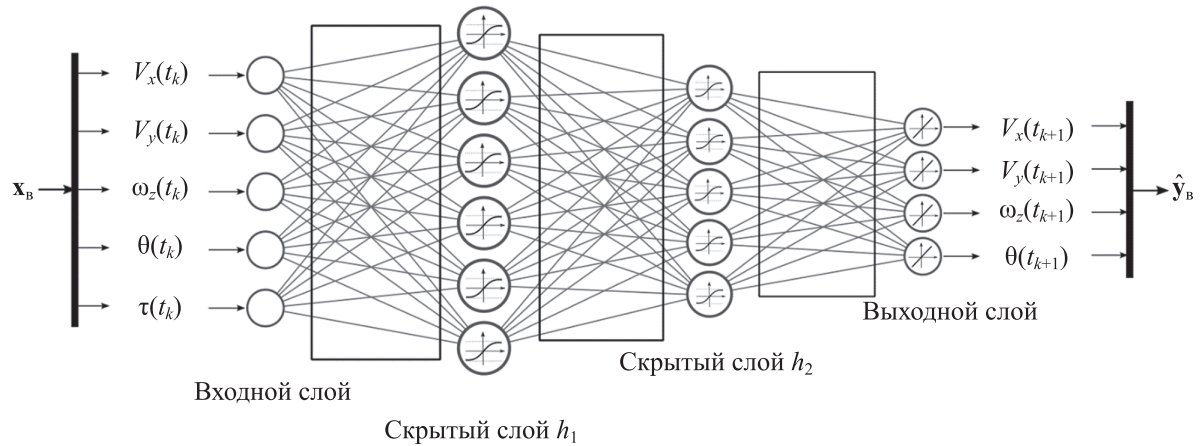


Рис. 4

Дальнейшее исследование направлено на определение оптимальной архитектуры НЭ. Для этого в течение 50 эпох было проведено предобучение искусственной нейронной сети с числом слоев от 3 до 15 и с количеством нейронов в скрытых слоях от 10 до 40. В качестве метрики сравнения использовалась RMSE:

$$\text{RMSE} = \sqrt{\frac{1}{L} \sum_{i=1}^L \|y_i - y_i^*\|^2}, \quad (3)$$

где y_i — выходное значение прогноза с номером i из обучающей выборки, y_i^* — фактическое выходное значение ИНС, L — число обучающих примеров, $\|y\|$ — норма вектора y . Для нормирования к безразмерным величинам покомпонентно вычисляется стандартизованная оценка элементов вектора выходных значений y . Результаты предобучения сведены в таблицу.

Размер скрытого слоя	RMSE, при числе слоев в сети					
	3	4	5	8	10	15
10	0,80	0,52	0,36	0,45	0,37	0,40
15	0,84	0,74	0,71	0,49	0,37	0,45
25	0,86	0,42	0,44	0,28	0,24	0,22
35	0,68	0,37	0,30	0,33	0,08	0,20
40	0,63	0,36	0,28	0,25	0,08	0,19

Анализ точности нейроэмулятора. Для верификации нейроэмулятора динамической модели АНПА проведено имитационное моделирование управляемой динамики в вертикальной плоскости. В работе в качестве эталонной использована разработанная классическими методами теоретической механики нелинейная динамическая модель (НДМ) управляемого движения аппарата. Анализ близости выходных значений НДМ и НЭ позволяет сделать выводы об адекватности построения прогнозирующей модели в виде глубокой нейронной сети. В качестве входного управляющего воздействия использован случайный сигнал с равномерным распределением вероятности, одновременно формируемым для обеих моделей генератором случайных

чисел. На рис. 5 и 6 представлены результаты моделирования в виде графиков ошибок выхода НЭ по отношению к НДМ.

Результаты показывают, что ошибка НЭ на устоявшемся интервале моделирования не превышает 0,2 % от номинальных значений, что свидетельствует об адекватности синтезированного НЭ управляемому движению АНПА.




Рис. 5




Рис. 6

Заключение. Таким образом, в статье представлены результаты структурного и параметрического синтеза нейросетевого эмулятора динамики АНПА. Представлена схема обучения нейроэмулятора динамики, предложена архитектура нейронной сети для решения задачи прогнозирования динамики, особенностью этой архитектуры является применение вспомогательных автоэнкодеров для инициализации коэффициентов нейронных связей. Для выбранной архитектуры нейронной сети приведены результаты верификации НЭ относительно эталонной модели АНПА, показывающие адекватность синтеза ПМ. Дальнейшие исследования могут быть направлены на применение в нейроэмуляторе альтернативных методов машинного обучения, таких как рекуррентные ИНС, деревья решений и градиентный бустинг.

СПИСОК ЛИТЕРАТУРЫ

1. Инзарцев А. В., Киселев Л. В., Костенко В. В., Матвиенко Ю. В., Павин А. М., Щербатюк А. Ф. Подводные робототехнические комплексы: системы, технологии, применение. Владивосток: Ин-т проблем морских технологий ДВО РАН, 2018. 368 с.
2. Budiyo A. Model predictive control for autonomous underwater vehicle // Indian J. of GeoMarine Sciences. 2011. Vol. 40, N 2. P. 191–199.
3. Сотникова М. В. Вопросы устойчивости движений в системах управления с прогнозирующими моделями // Вестник Воронежского государственного технического университета. 2012. Т. 8, № 1. С. 72–79.
4. Борисов А. Н., Сиек Ю. Л. Управление движением автономного необитаемого подводного аппарата на основе прогнозирующей модели // Морской вестник. 2020. № 4(76). С. 98–101.
5. Борисов А. Н., Сиек Ю. Л. Оценка производительности алгоритма оптимизации для управления с предсказанием автономным подводным аппаратом // Современные методы и средства океанологических исследований (МСОИ-2019). Матер. XVI Всерос. науч.-техн. конф. Т. II. М.: ИД Академии Жуковского, 2019. С. 103–106.
6. Borisov A. N., Siek J. L. A parallel optimization algorithm for predictive control of marine vessel // Journal of Physics: Conf. Ser.: Intern. Conf. "Information Technologies in Business and Industry". Novosibirsk: Institute of Physics Publishing, 2019. Vol. 1333, N 4. P. 042004. DOI 10.1088/1742-6596/1333/4/042004.
7. Fossen Th. I. Handbook of Marine Craft Hydrodynamics and Motion Control. John Wiley & Sons Ltd., 2011. 582 p.
8. Никущенко Д. В., Надымов Е. Н., Шушков Р. А. Расчет гидродинамических характеристик подводных аппаратов с выступающими частями, рулями и стабилизаторами // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2010. № 4. С. 63–73.
9. Кузнецов Б. И., Василец Т. Е., Варфоломеев А. А. Управление нелинейным динамическим объектом при помощи нейроконтроллера с предсказанием // Восточно-Европейский журнал передовых технологий. 2008. Т. 2, № 2(32). С. 67–71.
10. Бураков М. В. Нейронные сети и нейроконтроллеры: учеб. пособие. СПб: ГУАП, 2013. 284 с.
11. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016. 781 p.
12. Glorot X. & Bengio Y. Understanding the difficulty of training deep feedforward neural networks // Journal of Machine Learning Research — Proceedings Track. 2010. N 9. P. 249–256.
13. He K., Zhang X., Ren S., and Sun J. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification // IEEE Intern. Conf. on Computer Vision (ICCV 2015). Santiago, Chile, 2015. P. 1026–1034. DOI: 10.1109/ICCV.2015.123.
14. Сиек Ю. Л., Борисов А. Н., Журкин П. О. Разработка симулятора для моделирования управляемого движения автономного необитаемого подводного аппарата // Труды Санкт-Петербургского государственного морского технического университета. 2023. № 2(6). С. 153–169.
15. Борисов А. Н., Сиек Ю. Л. Оценивание параметров движения автономного необитаемого подводного аппарата на основе полумарковского процесса // Навигация и управление движением: Матер. XXII конф. молодых ученых с международным участием. СПб, 17–20 марта 2020 года. С. 295–297.

СВЕДЕНИЯ ОБ АВТОРАХ

- Александр Николаевич Борисов** — канд. техн. наук; Санкт-Петербургский государственный морской технический университет, кафедра САУиБВТ; доцент;
E-mail: bor_fond93@mail.ru
- Маргарита Александровна Борисова** — аспирант; Санкт-Петербургский государственный морской технический университет, кафедра САУиБВТ;
E-mail: margo.borisova.97@mail.ru
- Юрий Леонардович Сиек** — д-р техн. наук, профессор; Санкт-Петербургский государственный морской технический университет, кафедра САУиБВТ; заведующий кафедрой; E-mail: siek@mail.ru

Поступила в редакцию 10.07.24; одобрена после рецензирования 09.09.24; принята к публикации 21.11.24.

REFERENCES

1. Inzartsev A.V., Kiselev L.V., Kostenko V.V., Matvienko Yu.V., Pavin A.M., Shcherbatyuk A.F. *Podvodnyye robototekhnicheskiye komplekсы: sistemy, tekhnologii, primeneniye* (Underwater Robotic Systems: Systems, Technologies, Applications), Vladivostok, 2018, 368 p. (in Russ.)

2. Budiyo A. *Indian J. of GeoMarine Sciences*, 2011, no. 2(40), pp. 191–199.
3. Sotnikova M.V. *Vestnik Voronezhskogo gosudarstvennogo tekhnicheskogo universiteta*, 2012, no. 1(8), pp. 72–79. (in Russ.)
4. Borisov A.N., Siek Yu.L. *Morskoy Vestnik*, 2020, no. 4(76), pp. 98–101. (in Russ.)
5. Borisov A.N., Siek J.L. *Sovremennyye metody i sredstva okeanologicheskikh issledovaniy (MSOI-2019)* (Modern Methods and Tools for Oceanological Research (MSOI-2019)), Proc. of the XVI All-Russian Scientific and Technical Conf., Moscow, 2019, vol. II, pp. 103–106. (in Russ.)
6. Borisov A.N., Siek J.L. *Journal of Physics: Conference Series, Information Technologies in Business and Industry*, Novosibirsk, 2019, vol. 1333, pp. 042004, DOI 10.1088/1742-6596/1333/4/042004.
7. Fossen T.I. *Handbook of Marine Craft Hydrodynamics and Motion Control*, John Wiley & Sons Ltd., 2011, 582 p.
8. Nikushchenko D.V., Nadymov E.N., Shushkov R.A. *Bulletin of St. Petersburg University. Applied Mathematics. Computer Science. Control Processes*, 2010, no. 4, pp. 63–73. (in Russ.)
9. Kuznetsov B.I., Vasilets T.E., Varfolomeev A.A. *East European Journal of Advanced Technologies*, 2008, no. 2(2), pp. 67–71. (in Russ.)
10. Burakov M.V. *Neyronnyye seti i neyrokontrollery* (Neural Networks and Neurocontrollers), St. Petersburg, 2013, 284 p. (in Russ.)
11. Glorot X. & Bengio Y. *Journal of Machine Learning Research – Proceedings Track*, 2010, no. 9, pp. 249–256.
12. He K., Zhang X., Ren S., and Sun J. *IEEE Intern. Conf. on Computer Vision (ICCV 2015)*, Santiago, Chile, 2015, pp. 1026–1034, DOI: 10.1109/ICCV.2015.123.
13. Goodfellow I., Bengio Y., Courville A. *Deep Learning*, MIT Press, 2016, 781 p.
14. Siek Yu.L., Borisov A.N., Zhurkin P.O. *Proc. of the Saint-Petersburg State Marine Technical University*, 2023, no. 2(6), pp. 153–169. (in Russ.)
15. Borisov A.N., Siek Yu.L. *Navigatsiya i upravleniye dvizheniyem* (Navigation and Motion Control), Proc. of the XXII Conference of Young Scientists with International Participation, Saint-Petersburg, March 17–20, 2020, pp. 295–297. (in Russ.)

DATA ON AUTHORS

Aleksandr N. Borisov

— PhD, Associate Professor; State Marine Technical University, Department of Automatic Control Systems and Onboard Computer Facilities;
E-mail: bor_fond93@mail.ru

Margarita A. Borisova

— Post-Graduate Student; State Marine Technical University, Department of Automatic Control Systems and Onboard Computer Facilities;
E-mail: margo.borisova.97@mail.ru

Yury L. Siek

— Dr. Sci., Professor; State Marine Technical University, Department of Automatic Control Systems and Onboard Computer Facilities; Head of the Department; E-mail: siek@mail.ru

Received 10.07.24; approved after reviewing 09.09.24; accepted for publication 21.11.24.