

МАШИННОЕ ОБУЧЕНИЕ НЕЙРОСЕТЕВОГО КЛАССИФИКАТОРА ДЛЯ ИНТЕЛЛЕКТУАЛЬНОГО АВТОРУЛЕВОГО НА НЕЧЕТКОЙ ЛОГИКЕ

MACHINE LEARNING OF NEURAL NETWORK CLASSIFIER FOR INTELLIGENT AUTOPILOT ON FUZZY LOGIC

**N. Sedova
R. Bazhenov
A. Dorofeev
S. Glushkov**

Summary. The article reflects the results of the development of an intelligent autopilot model, where a neural network classifier was used to adapt the regulator, which selects the parameters of such a regulator in accordance with neural network ships models obtained from their trajectories. The article reflects the results of the development of an intelligent autopilot model, where a neural network classifier was used to adapt the regulator, which selects the parameters of such a regulator in accordance with neural network ships models obtained from their trajectories.

Using a certified signal simulator for autopilots, ships movement trajectories for different types of vessels under different sailing conditions were obtained. The optimization selection of the type, architecture and learning algorithm of the neural network for each trajectory was carried out. A spectral analysis showing the change in the spectral characteristics of ship models when changing weather conditions was done. The knowledge base of the neural network classifier of 24 neural network models of sea ships trajectories was formed, and usability of proposed approach was shown.

Keywords: navigation safety, intelligent autopilot, machine learning methods, classifier, fuzzy logic controller, neural network.

Седова Нелли Алексеевна

*К.т.н., доцент, Морской государственный университет им. адм. Г.И. Невельского (г. Владивосток)
nellyfish81@mail.ru*

Баженов Руслан Иванович

*К.п.н., доцент, Приамурский государственный университет им. Шолом-Алейхема (г. Биробиджан)
r-i-bazhenov@yandex.ru*

Дорофеев Андрей Сергеевич

*К.т.н., доцент, Иркутский национальный исследовательский технический университет (г. Иркутск)
dorbaik2007@mail.ru*

Глушков Сергей Витальевич

*Д.т.н., профессор, Морской государственный университет им. адм. Г.И. Невельского (г. Владивосток)
glushkov@msun.ru*

Аннотация. В работе приведены различные подходы к разработке интеллектуальных авторулевых, при этом указаны преимущества тех или иных интеллектуальных систем. Отмечается, что использование методов машинного обучения, в том числе нейросетевых технологий, является перспективным подходом в связи с многочисленными возможностями по обработке больших массивов данных. Предложено использование методов машинного обучения для формирования нейросетевых моделей, имитирующих траектории движения судов, а также для разработки нейросетевого классификатора, который группирует эти траектории по критериальным признакам. Таким образом, разрабатываемый авторулевой, регулятор которого настраивается классификатором в соответствии с характеристиками движения судна (зависящими от ветро-волновых условий плавания, типа, загрузки судна и т.д.) получает возможность самоадаптации под текущие условия плавания.

С использованием сертифицированного имитатора сигнала для авторулевых получены траектории движения судов (для разных типов судов при различных условиях плавания), для каждой траектории проведен оптимизационный подбор типа, архитектуры и алгоритма обучения нейронной сети. Проведен спектральный анализ, показывающий изменение спектральной характеристики моделей судов при смене погодных условий. Сформирована база знаний нейросетевого классификатора из 24 нейросетевых моделей траекторий движения морских судов, показана принципиальная работоспособность предложенного подхода.

Ключевые слова: безопасность мореплавания, интеллектуальный авторулевой, методы машинного обучения, классификатор, регулятор на нечеткой логике, нейронная сеть.

Введение

Обеспечение безопасного мореплавания актуально в настоящее время в связи с существующей высокой интенсивностью судоходства, регулярным ростом цен на топливо для судовых силовых установок, усилением экологических аспектов эксплуатации морского флота. Также следует отметить строительство скоростных и крупнотоннажных судов, управление которыми на качественном уровне требует дополнительных средств автоматизации процессов судовождения [1]. Для автоматизированного или автоматического решения различных навигационных задач, связанных с обеспечением безопасности судоходства, например, при удержании судна на курсе, целесообразно использовать авторулевыми, оптимально настраивающий параметры системы. Такой адаптивный авторулевой должен подстраиваться под внешние силы, которые воздействуют на судно.

Поскольку морское судно относится к весьма сложным в построении математической модели объектам управления [2], то использование традиционных пропорционально-интегрально-дифференциальных (ПИД) систем управления не является оптимальным. Это вызвано тем, что во время эксплуатации системы параметры и внешние воздействия меняются случайным образом и в достаточно широком диапазоне (направление и сила ветра, высота и длина волны, гидродинамические характеристики судна, осадка, глубина воды под килем, скорость хода судна).

Интеллектуальные авторулевы являются развитием адаптивных систем в направлении расширения возможностей выполнения более сложных задач в неопределённой среде при неполной информации, возникающих при решении значительного числа задач судовождения [3]. К интеллектуальным авторулевым принято относить авторулевы, использующие математический аппарат теории систем искусственного интеллекта, в том числе машинного обучения (чаще всего теории искусственных нейронных сетей или эволюционных алгоритмов), систем на основе нечёткой логики или их комбинации, так как именно такие системы способны качественно управлять процессами со сложно формализуемыми математическими моделями в различных условиях (нестационарных, нелинейных, со случайными внешними воздействиями и т.д.).

Интеллектуальные авторулевы на основе алгоритмов машинного обучения

В качестве интеллектуальных авторулевых целесообразно использовать авторулевы на основе алгорит-

мов машинного обучения по ряду преимуществ перед классическими авторулевыми, (пропорционально-дифференциальным и ПИД-авторулевым) [3–5], к основным преимуществам относятся: способность управлять многомерными процессами и системами без значительного увеличения времени необходимых вычислений, возможность интегрировать частные данные для определения закономерностей процесса управления, а также возможность неаналитического представления нелинейных объектов управления и описания процессов, характеризующихся неоднозначностью и большим количеством самых разных возмущающих воздействий.

В настоящее время особенно развиваются интеллектуальные авторулевы, использующие алгоритмы машинного обучения, способные к обучению на примерах, например, нейронные сети. Многочисленные проведённые натурные или полунатурные испытания служат источником для формирования обучающих выборок для таких алгоритмов. Нейронным сетям приписывают множество достоинств: параллельный механизм обработки данных, способность прогнозировать изменения входной информации, сохранение работоспособности при частичном выходе из строя элементов и связей нейронной сети и т.д.

Недостаток нейронных сетей заключается в том, что они не являются универсальными, поэтому чтобы перепрограммировать нейронную сеть на решение новой задачи, необходимо фактически заново создать её внутреннюю архитектуру. Однако подобное сужение специализации нейронных сетей компенсируется их способностью к обучению: при соответствующем обучении нейронная сеть приобретает способность выполнять практически любые преобразования данных.

Нейронные сети при управлении морским судном могут использоваться несколькими способами: при непосредственном создании интеллектуального авторулевого, при построении блока настройки коэффициентов традиционного (например, ПИД) авторулевого и при формировании нейросетевой модели движения морского судна.

Например, в работе [6] предложена интеллектуальная система управления транспортом, в которой в качестве регулятора используется регулятор на базе вейвлет-нейронной сети. Предлагаемая система управления включает нейросетевой контроллер. Подобные стратегии управления, связанные с контролем траектории хорошо зарекомендовали себя, в частности, в работах [7, 8].

Удержание судна типа нефтяной танкер на курсе успешно проведено с использованием регулятора

на базе адаптивной нейро-нечеткой системы вывода (ANFIS), как показано в работе [9]. Авторы отмечают, что при нелинейном и движении судна контроллер удержания курса на базе ANFIS успешно справляется с оптимальной настройкой параметров.

Методы машинного обучения успешно используются для отслеживания траектории движения морского судна, а также для прогнозирования поведения морского судна, как показано, например, в работе [10].

Интеллектуальные авторулевые на основе эволюционных алгоритмов

Помимо нейросетевых технологий также могут использоваться эволюционные алгоритмы, осуществляющие обучение с подкреплением [11]. Эволюционные алгоритмы при управлении морским судном могут использоваться следующими способами: при идентификации параметров объекта управления; для настройки параметров классических (на основе ПИД-управления, например) авторулевых; для поиска оптимальных параметров нечетких или нейросетевых авторулевых.

Так, исследователями [12] изучены некоторые способы формирования закона управления, в том числе классические контроллеры, настроенные с использованием эволюционных алгоритмов. В работе [13] авторами настоящей работы предложен и исследован интеллектуальный авторулевой для морских судов, содержащий нечеткий регулятор, настройка параметров которого осуществляется эволюционным алгоритмом по соответствующим нейросетевым моделям траекторий движения морских судов.

При введении эволюционного алгоритма в качестве оптимизирующей составляющей параметров нейронной сети, возникает необходимость соответствующего хромосомного представления данных, т.е. должен быть создан способ эволюционного кодирования всех возможных вариантов нейронных сетей.

В результате применения эволюционных алгоритмов с выбранным методом селекции хромосом формируется новая популяция особей (потомков). Последующие шаги алгоритма повторяются для очередной популяции вплоть до выполнения условия завершения. Наилучшая особь из последнего поколения считается наилучшим множеством весов, наилучшей архитектурой и наилучшим правилом обучения нейронных сетей.

В работе применяется так называемый гибридный подход, состоящий в объединении двух методов. Вначале при помощи эволюционного алгоритма находится

решение достаточно близкое к оптимальному, затем решение уточняется, используя ползущий метод случайного поиска. В качестве оптимизатора также перспективным представляется алгоритм дифференциальной эволюции [15].

Архитектура интеллектуального авторулевого включает (помимо регулятора на нечеткой логике, параметры которого определяются блоком оптимизации на базе эволюционного алгоритма по соответствующим нейросетевым моделям траекторий движения морских судов) нейросетевой классификатор [14], предназначенный для классификации траекторий движения морских судов для выявления особенностей поведения судна по курсу (неявно учитываются особенности влияния погодных факторов, изменения кладок пера руля и т.д.). Также в указанной работе были представлены результаты проведенного полунатурного (компьютерного на базе информации от имитатора сигналов для авторулевых) и натурного испытаний, на примере судна типа транспортный рефрижератор.

Целью настоящей работы является продолжение исследований, изложенных в работе [13], которая заключается в представлении методики синтеза нейросетевого классификатора, включенного в состав интеллектуального авторулевого.

Так, морское судно обладает определенными гидродинамическими характеристиками, которые отражают способность к управлению, устойчивости движения по курсу. Эти характеристики определяются, в первую очередь, относительной скоростью движения судна, эффективностью воздействия пера руля, отношениями длины, ширины и осадки корпуса, а также погодными факторами, связанными с силой ветра, высотой, периодом и направлением волнения. Более того, в зависимости от загрузки судна, режима работы главной энергоустановки и погодных факторов динамика движения судна по курсу будет разной, а, следовательно, разными должны быть и настройки интеллектуального авторулевого, чтобы обеспечить наилучшее движение судна по курсу.

Наилучшая настройка интеллектуального авторулевого в режиме реального времени представляется затруднительной, т.к. основывается на пробных экспериментах с реально движущимся судном и приводит к дополнительным тратам времени, топлива, и может служить причиной аварийных ситуаций. Разработка и внедрение интеллектуального классификатора в структуру разрабатываемого интеллектуального авторулевого позволит учитывать особенности поведения судна на курсе наилучшим образом настраивать регулятор на нечеткой логике авторулевого. Научная

новизна интеллектуального классификатора заключается в использовании спектрального анализа траектории движения судна по курсу при соответствующей кривой команд изменения положения пера руля. Для проведения спектрального анализа предложено использовать дискретное преобразование Фурье (ДПФ).

При разработке нейросетевого классификатора интеллектуального авторулевого использовался ряд методов получения результатов: для формирования критериальных признаков, по которым интеллектуальный классификатор принимает решение об оптимальных нейросетевых моделях траекторий движения судов, использовались методы спектрального анализа, в частности, метод ДПФ, для получения нейросетевых моделей траекторий движения морских судов проводилось компьютерное моделирование на имитаторе сигналов для авторулевых ИС-2005 (Производитель: Engineering Center of Information and Control Systems, St. Petersburg, Russia) и алгоритмы машинного обучения для формирования соответствующих параметров нейросетевых моделей, для классификации указанных траекторий также использовались алгоритмы машинного обучения на примере нейронных сетей с радиально-базисными функциями активации, наконец, для проверки работоспособности описанного нейросетевого классификатора проведено имитационное моделирование при различных скоростях движения морских судов и различных погодных условиях.

Получение критериальных признаков для классификатора интеллектуального авторулевого

Методика проведения спектрального анализа для траекторий движения морских судов заключается в следующей совокупности шагов. На первом шаге проведено компьютерное моделирование на имитаторе сигналов для авторулевых ИС-2005. Для моделирования использовались следующие модели морских судов: пассажирское судно прибрежного плавания (ПСПП) длиной 35,5 м, траулер длиной 85 м, транспортный рефрижератор длиной 107,8 м, автомобильно-пассажирское судно длиной 158 м, танкер длиной 179,9 м и супертанкер длиной 325 м. На втором шаге кривые переходных процессов движения судов, полученные с помощью имитатора сигналов, поступают в специально разработанный модуль, в котором реализуется разложение этих данных в спектр с помощью ДПФ [16], при этом решается задача по выбору числа гармоник, которые, с одной стороны, обеспечат качественное восстановление первоначальной траектории движения судна, а с другой стороны, позволят сформировать обучающую выборку достаточного размера для нейросетевого классификатора. Например, в случае

использования 16 гармоник нейронная сеть, используемая в качестве классификатора, содержит 65 входов, что значительно сказывается на скорости процесса классификации по сравнению с 33 входами для 8 гармоник. На третьем шаге для проверки достоверности проведённого спектрального анализа восстанавливается траектория движения судна с помощью обратного преобразования Фурье и сравнивается с исходной траекторией движения судна, полученной с помощью имитатора сигналов для авторулевых ИС-2005. После проверки данные поступают на разработанный авторами генератор сигналов, этот модуль генерирует сигнал по восьми максимальным гармоникам (определяются коэффициенты амплитуды и частоты для восьми максимальных гармоник) и определяет соответствующую интегральную составляющую.

Анализ проведённых исследований показал, что для каждого из типов судов присущи свои уникальные спектральные характеристики, характеризующие движение судна по курсу в определенных погодных условиях, что может служить идентификационными метками в нейросетевом классификаторе. Получено, что для малотоннажных судов (ПСПП, траулер) спектр частот является более разнообразным и насыщенным, чем для крупнотоннажных, у которых основными являются первые две гармоники, у малотоннажных судов основными являются не первые частоты.

После проведения спектрального анализа и получения восьми максимальных гармоник для каждой модели морского судна рассчитывается интегральный критерий I . В работе приведено исследование возможности использования меньшего числа гармоник для идентификации нейросетевой модели траекторий движения судов, содержащихся в базе знаний нейросетевого классификатора. Здесь, основной сигнал Y_1 состоит из суммы восьми составляющих, а сравниваемый сигнал Y_2 состоит из суммы исследуемого количества составляющих:

$$Y_1 = \sum_{i=1}^8 A_i \sin(\omega_i dt); Y_2 = \sum_{i=1}^N A_i \sin(\omega_i dt);$$

$$I = \frac{1}{T} \int_0^T |Y_1 - Y_2| dt,$$

$$\text{где } dt = \frac{2\pi}{\omega N}; \omega —$$

наименьшая частота из заданных гармоник; N — количество введенных гармоник.

После проведения компьютерного моделирования на имитаторе сигналов для авторулевых ИС-2005 с моделями шести морских типов судов при четырёх раз-

личных погодных условиях (скорость ветра 1–2 м/сек, высота волны 3% обеспеченности 0,25 м; скорость ветра 2–5 м/сек, высота волны 0,85 м; скорость ветра 5–8 м/сек, высота волны 1,25 м; скорость ветра 8–10 м/сек, высота волны 1,25 м) и проведения ДПФ были получены векторы меток, характеризующие коэффициенты амплитуд восьми основных гармоник при изменении значений курса судна, угловой скорости рыскания, угла кладки руля и средней линейной скорости (всего 65 элементов для каждого вектора) [16]. Анализ полученных данных показал ярко выраженную зависимость интегральной составляющей ошибки I от количества гармоник при моделировании движения судна. Если для крупнотоннажных судов можно ограничиться двумя-тремя гармониками, то для судов малого водоизмещения необходимы восемь гармоник. Также из анализа полученных результатов был сделан вывод об изменении спектральной характеристики моделей судов при смене погодных условий, что особенно характерно для малотоннажных судов типа ПСПП и траулер.

Проведенные исследования для всех рассматриваемых моделей морских судов показали, что погрешность моделирования различных типов судов по-разному зависит от количества участвующих гармоник. Если у малотоннажных судов наблюдается зависимость близкая к линейной, то у более инерционных крупнотоннажных судов — нелинейная, поэтому возможно использование меньшего количества гармоник.

Классификация траекторий движения морских судов нейросетевым классификатором

Для классификации траекторий движения морских судов со спектральными характеристиками в качестве критериальных признаков предпочтительным является использование нейронных сетей с радиально-базисными функциями активации (РБФ) [16]. Гибридный алгоритм обучения нейронных сетей РБФ сначала оценивает позицию и ширину ядра с использованием алгоритма кластеризации «без учителя», а затем используется алгоритм минимизации среднеквадратической ошибки «с учителем», который определяет веса связей между скрытым и выходным линейным слоями. После получения этого начального приближения используется градиентный спуск для уточнения параметров нейронной сети (НС). Этот смешанный алгоритм обучения НС РБФ сходится гораздо быстрее, чем алгоритм обратного распространения, применяемый для обучения многослойных НС прямого распространения, однако НС РБФ содержит слишком большое число скрытых элементов, что влечет более медленное функционирование НС РБФ, чем многослойная НС прямого распространения.

Расположение центров должно соответствовать кластерам, реально присутствующим в исходных данных. Проведенный ранее спектральный анализ позволил сформировать обучающую выборку для обучения нейронной сети с РБФ, состоящую из 96 примеров. Данные считывались из файлов, масштабировались и заносились в массив.

Кластеризация выполнялась по методу «к-средних» каждого из классов на шесть кластеров с использование функции « k -means», т.е. в каждом кластере оказалось по 24 объекта. Используемый алгоритм k -средних стремится выбрать оптимальное множество точек, являющихся центроидами кластеров в обучающих данных. При k радиальных элементах их центры располагаются таким образом, чтобы каждая обучающая точка «относилась» к одному центру кластера и лежала к нему ближе, чем к любому другому центру, а также каждый центр кластера был центроидом множества обучающих точек, относящихся к этому кластеру.

Векторы центроидов кластеров заносились в специальный массив. Следующим шагом было определение отклонений гауссовой функции для каждого центроида кластеров, для чего применяли наиболее точный и эффективный метод « k -ближайших соседей». Радиус колокола каждого ядра рассчитывался как средняя дистанция до $k = 3$ (компьютерное моделирование показало, что ошибка НС наименьшая при $k = 3$) ближайших соседних центроидов и записывался в массив. Результатом подобного обучения являются весовые коэффициенты — векторы центроидов и пороговые уровни слоя — отклонения из массива. В результате получены отклики функций Гаусса для каждого из шести типов морских судов.

Полученные на рисунке 3 кластеры представляют собой идентификационные метки P_j , соответствующие конкретному типу судна при соответствующих погодных условиях, использующиеся для классификации.

После получения критериальных признаков осуществляется обучение нейросетевого классификатора, в результате которого настраиваются параметры классификатора, в этом случае производится сравнение идентификационных меток P_j с условными частями A_{cond} всех классификаторов C_r . При совпадении условных частей соответствующие классификаторы объявляются активными и участвуют в дальнейших вычислениях: каждый активный классификатор выполняет последовательность процедур «алгоритма пожарной бригады», в результате которого над классификатором, имеющим максимальную силу S_r , выполняются опробование в работе. Изначально каждому классификатору присваивается значение силы S_r , равное единице, в дальнейшем, при

сравнении условных частей A_{cond} всех классификаторов C_r с вектором идентификационных меток P_j происходит изменение величины силы. При этом, когда все активные классификаторы имеют одинаковую силу и/или «алгоритм пожарной бригады» осуществил 1000 итераций, над условными частями A_{cond} классификаторов C_r выполняют последовательность процедур генетического алгоритма. При этом, в частном случае, когда ни один из классификаторов не объявляется активным, производят процедуру, согласно которой в векторе идентификационных меток P_j некоторые символы заменяются на символ «#», образуя вектор $P_j^\#$, после этого в классификаторе с минимальной силой S_r условная часть A_{cond} заменяется на вектор $P_j^\#$. В соответствии с действием выигравшей условной части правила A_{cond} этого классификатора выбирают ту нейросетевую модель траектории движения судна нейронную сеть, которая соответствует этому классификатору [14].

Итогом проведённых экспериментов и обучения нейросетевого классификатора стала база знаний на 24 нейросетевые модели траекторий движения шести различных морских судов при различных условиях плавания [14].

Заключение

В работе приведены примеры успешного использования алгоритмов машинного обучения и эволюционных алгоритмов для решения задач, тесно связанных с судовождением: разработка авторулевых как содержащих интеллектуальные авторулевые, так и авторулевых,

содержащих классические (включающие пропорционально-дифференциальный или ПИД регуляторы) авторулевые, настройка параметров который осуществляется с использованием алгоритмов машинного обучения. Авторами предложена модель интеллектуального авторулевого, содержащего нейросетевой классификатор, осуществляющий адаптацию нечёткого регулятора. В работе приведена методика получения критериальных признаков, необходимых для классификатора предложенного интеллектуального авторулевого. С использованием сертифицированного имитатора сигнала для авторулевых получены 24 траектории движения судов (для разных типов судов при различных условиях плавания), при этом для каждой траектории получена соответствующая нейросетевая модель, причём общее число синтезированных нейросетевых моделей движения судов при различных погодных условиях, скорости и водоизмещении судна равняется 2528. Из различных архитектур нейронных сетей выбраны наилучшие, которые на всём множестве нейросетевых моделей траекторий движения судов показали наилучшие результаты (минимальные значения среднеквадратичного отклонения достигались порядка 10^{-7} , подробное изложение полученных результатов представлено в [13]). Проведён спектральный анализ, результаты которого свидетельствуют о том, что для крупнотоннажных судов можно ограничиться двумя-тремя гармониками, а для судов малого водоизмещения, таких как ПСПП и траулер, необходимы восемь гармоник. Также из анализа данных можно сделать вывод об изменении спектральной характеристики моделей судов при смене погодных условий, что особенно характерно для малотоннажных судов.

ЛИТЕРАТУРА

1. Глушков, С.В. Управление курсом судна с использованием интеллектуальной системы / С.В. Глушков, Н.А. Седова // Вестник Морского государственного университета. — 2010. — № 37. — С. 2–8.
2. V. Deryabin, A. Sazonov. (2019). A Vessel's Dead Reckoning Position Estimation by Using of Neural Networks. Proceedings of the Third International Scientific Conference "Intelligent Information Technologies for Industry" (IITI'18), pp.493–502 Volume 1. DOI: 10.1007/978-3-030-01818-4_49.
3. Седова Н.А. Тенденции развития интеллектуальных авторулевых для морского транспорта // Гибридные и синергетические интеллектуальные системы: теория и практика. — Калининград: Изд-во БФУ им. И. Канта, 2012 — Ч. 1 / авт. предисл. А.В. Колесников. — 2012. — 181–188 с.
4. KM. Junaid, KM Usman, K. AttaUllah and JA. Raza, "A neural network based adaptive autopilot for marine applications" Proceedings of IEEE Conference on Cybernetics and Intelligent Systems, Bangkok, THAILAND, JUN2006, pp. 8.
5. GN. Roberts, R. Sutton, A. Zirilli and A. Tiano. (2003). Intelligent ship autopilots — A historical perspective. MECHATRONICS, Vol. 13, pp. 1091–1103, doi: 10.1016/S0957-4158(03)00044-8.
6. CH. Chen, "Intelligent transportation control system design using wavelet neural network and PID-type learning algorithms," Expert Systems with Applications, JUN2011, Vol. 38, pp. 6926–6939, DOI: 10.1016/j.eswa.2010.12.031.
7. Aguilar-Ibanez, C., & Suarez-Castanon, M.S. (2019). A Trajectory Planning Based Controller to Regulate an Uncertain 3D Overhead Crane System, International Journal of Applied Mathematics and Computer Science, 29(4), 693–702. doi: <https://doi.org/10.2478/amcs-2019-0051>
8. García-Sánchez, J.R., Tavera-Mosqueda, S., Silva-Ortigoza, R., Hernández-Guzmán, V.M., Sandoval-Gutiérrez, J., Marcelino-Aranda, M., Taud, H., & Marciano-Melchor, M. (2018). Robust Switched Tracking Control for Wheeled Mobile Robots Considering the Actuators and Drivers. Sensors (Basel, Switzerland), 18(12), 4316. <https://doi.org/10.3390/s18124316>
9. XJ. Chen and XK. Zhang, "Nonlinear Feedback Control Based on ANFIS," Proceedings of 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD), Zhangjiajie, PEOPLES R CHINA, AUG 2015, pp. 559–563.

10. GC. Zhang and G. Ren, "Research of ship track self-tuning adaptive control based on predicting model" Proceedings of International Conference on Complex Systems and Applications, Jinan, PEOPLES R CHINA, JUN2007, pp. 982–986.
11. Reeves C. (2003) Genetic Algorithms. In: Glover F., Kochenberger G.A. (eds) Handbook of Metaheuristics. International Series in Operations Research & Management Science, vol 57. Springer, Boston, MA. https://doi.org/10.1007/0-306-48056-5_3
12. FJ. Velasco, TM. Rueda, E. Lopez and E. Moyano, "Marine course-changing manoeuvre: A comparative study of control algorithms" IEEE International Conference on Control Applications, GLASGOW, SCOTLAND, Sep. 2002, pp. 1064–1069.
13. N. Sedova, V. Sedov, R. Bazhenov, I. Ledovskikh A Marine Autopilot With a Fuzzy Controller Computed by a Neural Network. 7th Scientific Conference on Information Technologies for Intelligent Decision Making Support (ITIDS2019), Vol. 166, 2019, p. 171–176. — Atlantis Press, 2019. <https://dx.doi.org/10.2991/itids-19.2019.31>.
14. Седова, Н.А. Компьютерное моделирование интеллектуального авторулевого для различных типов судов / Н.А. Седова // Вестник Морского государственного университета. — 2016. — № 75. — С. 104–107.
15. Suganthan P.N. (2012) Differential Evolution Algorithm: Recent Advances. In: Dediu A.H., Martín-Vide C., Truthe B. (eds) Theory and Practice of Natural Computing. TPNC2012. Lecture Notes in Computer Science, vol 7505. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-33860-1_4.
16. Патент № 2519315 С2 Российская Федерация, МПК В63Н 25/00. Способ автоматического управления судном по курсу и интеллектуальная система для осуществления способа: № 2012132893/11: заявл. 01.08.2012: опубл. 10.06.2014 / Н.А. Седова.

© Седова Нелли Алексеевна (nellyfish81@mail.ru), Баженов Руслан Иванович (r-i-bazhenov@yandex.ru), Дорофеев Андрей Сергеевич (dorbaik2007@mail.ru), Глушков Сергей Витальевич (glushkov@msun.ru).

Журнал «Современная наука: актуальные проблемы теории и практики»



г. Владивосток