

УДК 004.021

DOI: [10.26102/2310-6018/2022.38.3.003](https://doi.org/10.26102/2310-6018/2022.38.3.003)

Модифицированная нейронная сеть Элмана с динамическим показателем обучения для отслеживания и прогнозирования движения неголономного трехколесного мобильного робота

В.А. Березина✉, О.С. Мезенцева, Д.В. Мезенцев

Северо-Кавказский федеральный университет,
Ставрополь, Российская Федерация
BerezinaVA@yandex.ru✉

Резюме. В статье предлагается отслеживать и прогнозировать траекторию движения автономного неголономного трехколесного мобильного робота с помощью модифицированной нейронной сети Элмана. Предлагается алгоритм расчета показателя обучения нейронной сети, который способствует повышению эффективности и скорости обучения, а также снижает количество итераций, необходимых для обучения. Модифицированный алгоритм Элмана с динамическим показателем обучения сравнивается с классической нейронной сетью Элмана и PSO-алгоритмом. Обучение нейронной сети оценивается по двум критериям: количество итераций, необходимых для обучения, и среднее время обучения. Помимо этого, проверяется отклонение от заданной траектории движения: движения по прямой, по квадрату и по окружности для каждого алгоритма. Результаты моделирования показали, что модифицированная нейронная сеть Элмана с динамическим показателем обучения эффективнее (в среднем, на 32,4 %) и быстрее (в среднем, на 66,4 %) справляется с задачей обучения и имеет наименьшее отклонение от заданной траектории движения. Относительная погрешность измерений варьируется в диапазоне от 7,8 % до 20,2 % при 95 % уровне надежности и пяти испытаниях для каждой группы измерений.

Ключевые слова: рекуррентная нейронная сеть, нейронная сеть Элмана, показатель обучения, неголономный трехколесный робот, прогнозирование траектории движения.

Для цитирования: Березина В.А., Мезенцева О.С., Мезенцев Д.В. Разработка модифицированной нейронной сети Элмана для отслеживания и прогнозирования движения неголономного трехколесного мобильного робота. *Моделирование, оптимизация и информационные технологии*. 2022;10(3). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1199>
DOI: 10.26102/2310-6018/2022.38.3.003

Modified Elman neural network with dynamic learning rate for tracking and motion prediction of a nonholonomic three-wheeled mobile robot

V.A. Berezina✉, O.S. Mezentseva, D.V. Mezentsev

North-Caucasus Federal University,
Stavropol, Russian Federation
BerezinaVA@yandex.ru✉

Abstract. This article proposes to track and predict the trajectory of a non-holonomic three-wheeled mobile robot using a modified Elman neural network. An algorithm for calculating the learning rate of a neural network is suggested, which improves the efficiency and speed of learning and also reduces the number of iterations required for learning. The modified Elman algorithm with dynamic learning rate (MENN) is compared with the classical Elman neural network (ENN) and the PSO algorithm (PSO-ENN). Training of a neural network is evaluated according to two criteria: the number of iterations

required for training and the average training time. In addition, the deviation from the given trajectory of movement is checked: movement along a straight line, in a square and in a circle for each algorithm. The simulation results showed that the modified Elman neural network with a dynamic learning rate is more efficient (by 32.4% on average) and accomplishes the learning objective faster (by 66.4% on average) and has the least deviation from the given motion trajectory. The relative measurement error ranges from 7.8% to 20.2% at 95% reliability and five tests for each group of measurements.

Keywords: recurrent neural network, Elman neural network, learning rate, nonholonomic three-wheeled robot, motion trajectory prediction.

For citation: Berezina V.A., Mezentseva O.S., Mezentsev D.V. Modified Elman neural network with dynamic learning rate for tracking and motion prediction of a nonholonomic three-wheeled mobile robot. *Modeling, Optimization and Information Technology*. 2022;10(3). Available from: <https://moitvvt.ru/ru/journal/pdf?id=1199> DOI: 10.26102/2310-6018/2022.38.3.003 (In Russ.).

Введение

В последние годы колесные мобильные роботы привлекли значительное внимание в различных промышленных и сервисных приложениях. Например, уборка помещений, автоматизация производства, транспорт и т. д. Эти приложения требуют, чтобы мобильные роботы имели возможность стабильно отслеживать заданный путь [1], а иногда и самостоятельно строить маршрут [2]. В целом, неголономное поведение в робототехнических системах особенно актуально, поскольку такой системой можно полностью управлять с помощью меньшего количества исполнительных механизмов. Было предложено несколько контроллеров для отслеживания траектории мобильных роботов с неголономными ограничениями [3]. Традиционные методы управления для отслеживания пути мобильного робота используют линейное или нелинейное управление с обратной связью, в то время как контроллеры, основанные на искусственном интеллекте, используют нейронные сети или нечеткую логику [4].

Управление отслеживанием траектории неголономного мобильного робота путем интеграции кинематического контроллера и нейродинамического контроллера на основе теории скользящего режима было представлено в [5]. Адаптивные нейронные контроллеры с прямой и обратной связью с алгоритмом прогнозирующей оптимизации минимизировали ошибку отслеживания неголономного колесного мобильного робота [6].

Целью исследования является разработка нейросетевого алгоритма отслеживания и прогнозирования траектории движения неголономного мобильного робота, и решаются следующие задачи:

- описать кинематическую и динамическую модель неголономного трехколесного мобильного робота;
- определить структуру нейронной сети для отслеживания и прогнозирования траектории движения;
- выбрать алгоритм обучения нейронной сети;
- осуществить моделирование и провести сравнительный анализ алгоритмов обучения и отслеживания, прогнозирования траектории движения.

В предлагаемом исследовании для отслеживания и прогнозирования траектории движения неголономного робота используется нейронная сеть Элмана, которая является одним из видов рекуррентных сетей [7]. Нейронная сеть Элмана (ENN) имеет ряд преимуществ перед традиционными нейронными сетями, например, наличие слоя контекста, возможность «запоминать» предыдущие состояния и т. д.

Материалы и методы

Схема неголономного трехколесного мобильного робота представлена на Рисунке 1. Робот состоит из платформы с двумя ведущими колесами, установленными на одной оси, и всенаправленного колеса в передней части платформы, делающее платформу более стабильной [3 и 4]. Левое и правое колеса оснащены приводами для осуществления движения и ориентации. Колеса имеют одинаковый радиус, обозначаемый r , а L – расстояние между двумя колесами. Центр масс мобильного робота расположен в точке c , центре оси колес.

Положение мобильного робота в глобальной системе координат OXY и вектор положения определяются как [3]:

$$q = (x, y, \theta)^T, \quad (1)$$

где x и y – координаты точки c ; θ – угол ориентации робота, измеренный относительно оси X .

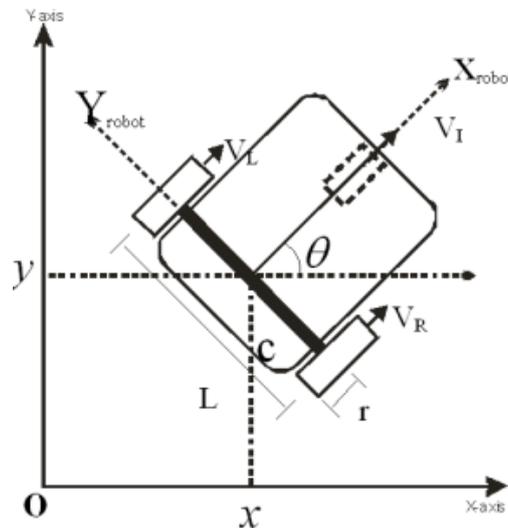


Рисунок 1 – Схема неголономного мобильного робота
Figure 1 – Scheme of a nonholonomic mobile robot

Эти три обобщенные координаты могут описывать конфигурацию мобильного робота. Мобильный робот подвергается независимому ограничению скорости, которое может быть выражено в матричной форме [8]:

$$A^T(q)\dot{q} = 0, \quad (2)$$

где

$$A^T(q) = [-\sin \theta(t) \quad \cos \theta(t) \quad 0], \quad (3)$$

где $A^T(q)$ – транспонированная матрица положения, \dot{q} – производная по времени вектора положения, $\theta(t)$ – угол ориентации робота.

Предполагается, что колеса мобильного робота установлены таким образом, чтобы они имели идеальное качество без проскальзывания [1]. Следовательно, кинематику робота можно описать как:

$$\dot{q} = \begin{bmatrix} \dot{x}(t) \\ \dot{y}(t) \\ \dot{\theta}(t) \end{bmatrix} = S(q) \begin{bmatrix} V_I(t) \\ V_W(t) \end{bmatrix}, \quad (4)$$

где

$$S(q) = \begin{bmatrix} \cos \theta(t) & 0 \\ \sin \theta(t) & 0 \\ 0 & 1 \end{bmatrix}, \quad (5)$$

где V_I и V_W – линейная и угловая скорости, $S(q)$ – матрица полного ранга, $\theta(t)$ – угол ориентации робота, $x(t), y(t), \theta(t)$ – производная по времени вектора положения (координат x и y и угла θ ориентации робота соответственно).

Силы должны быть приложены к мобильному роботу, чтобы произвести движение. Эти силы моделируются путем изучения движения динамической модели дифференциального колесного мобильного робота, показанного на Рисунке 1. Масса, силы и скорость связаны с этим движением. Динамическое уравнение, основанное на формулировке Эйлера-Лагранжа [8], дифференциального колесного мобильного робота можно представить в виде:

$$\begin{bmatrix} M & 0 & 0 \\ 0 & M & 0 \\ 0 & 0 & I \end{bmatrix} \begin{bmatrix} \ddot{x} \\ \ddot{y} \\ \ddot{\theta} \end{bmatrix} + \tau_d = \frac{1}{r} \begin{bmatrix} \cos \theta & \cos \theta \\ \sin \theta & \sin \theta \\ \frac{L}{2} & \frac{-L}{2} \end{bmatrix} \begin{bmatrix} \tau_L \\ \tau_R \end{bmatrix} + \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix} \lambda, \quad (6)$$

где M и I представляют массу и инерцию мобильного робота соответственно, $x(t), y(t), \theta(t)$ – вторая производная по времени вектора положения (координат x и y и угла θ ориентации робота соответственно), τ_d – ограниченные неизвестные возмущения, включая неструктурированную и не моделируемую динамику, r – радиус колес робота, L – расстояние между двумя колесами, τ_L и τ_R – крутящие моменты левого и правого мотора соответственно, λ – вектор ограничивающих сил.

Решая уравнения (4 и 6), получаем нормальную форму:

$$\dot{V}_I = \frac{\tau_L + \tau_R}{Mr} + \tau_d, \quad (7)$$

$$\dot{V}_W = \frac{L(\tau_L - \tau_R)}{2rI} + \tau_d, \quad (8)$$

где \dot{V}_I и \dot{V}_W – линейное и угловое ускорения дифференциально-колесного мобильного робота.

На основе [1] и указанных выше уравнениях разработана структура динамической и кинематической модели трехколесного колесного мобильного робота, представленная на Рисунке 2.

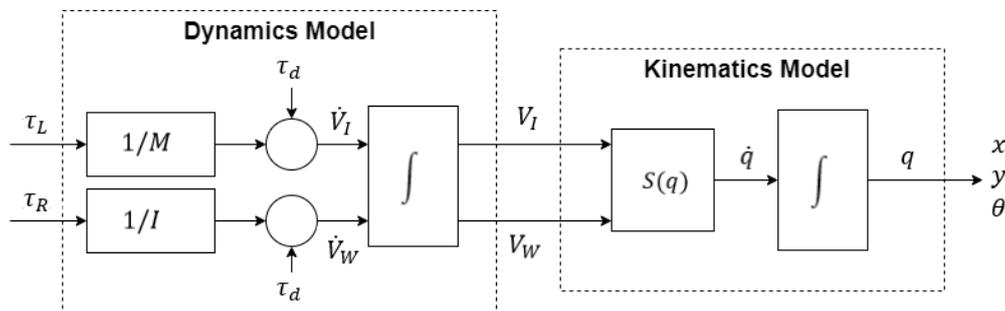


Рисунок 2 – Динамическая и кинематическая модели мобильного робота
Figure 2 – Dynamic and kinematic models of a mobile robot

Как видно из Рисунка 2, на вход динамическая модель получает крутящие моменты левого и правого мотора, а выходы (линейное и угловое ускорения дифференциально-колесного мобильного робота) являются входами кинематической

модели. Выход кинематической модели представляет собой вектор положения робота (координаты x и y и угол θ ориентации робота).

С учетом разработанной динамической и кинематической моделей мобильного робота предлагается структура модифицированной нейронной сети Элмана, которая представлена на Рисунке 3 и основана на следующих уравнениях [4]:

$$h(k) = F\{VHG(k), VC\bar{h}^o(k), bias\bar{V}b\} \quad (9)$$

$$O(k) = (Wh(k), bias\bar{W}b), \quad (10)$$

где $VHG(k)$, $VC\bar{h}^o(k)$ и $Wh(k)$ – весовые матрицы входного вектора, выходного вектора слоев и общего выходного вектора соответственно, Vb и Wb – весовые векторы, а F – нелинейная векторная функция.

Выход контекстного блока в модифицированной сети Элмана определяется выражением [8]:

$$h_c^o(k) = \alpha h_c^o(k-1) + \beta h_c(k-1), \quad (11)$$

где $h_c^o(k)$ и $h_c(k)$ – выходы контекстного и скрытого слоев соответственно, α – усиление обратных соединений, а β – вес соединений от скрытых узлов к контекстным узлам в контекстном блоке. Значения α и β выбираются случайным образом в диапазоне (0;1).

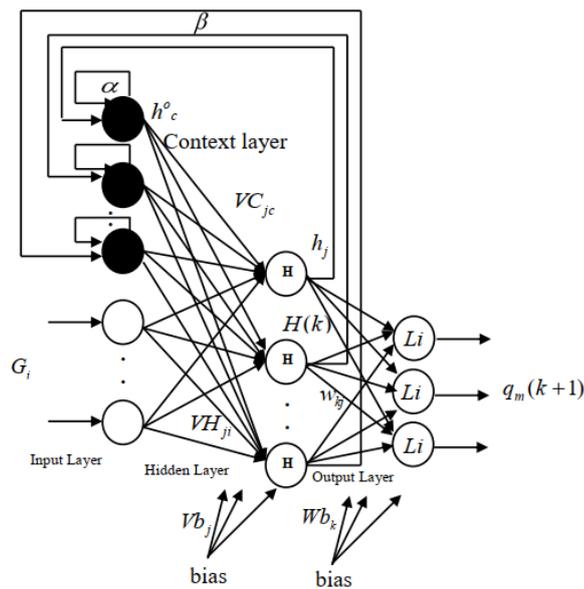


Рисунок 3 – Структура модифицированной нейронной сети Элмана
Figure 3 – Structure of Elman's modified neural network

Как видно из Рисунка 3, модифицированная нейронная сеть Элмана имеет узлы в контекстном слое, которые используются только для запоминания предыдущих активаций скрытых узлов, что позволит увеличить скорость обучения и уменьшить количество узлов в скрытом слое. При этом, для повышения качества обучения узлы в контекстном слое имеют возможность «самоподключения». Целью алгоритма обучения нейронной сети Элмана является минимизация среднеквадратичной ошибки [9]:

$$E(k) = \frac{\|e(k)\|^2}{2}, \quad (12)$$

где $e(k)$ – разница между желаемыми выходами нейронной сети и фактическими.

При этом стандартный метод обучения (обратное распространение ошибки)

оценивает вес следующим образом [10]:

$$W^{o,h}(k + 1) = W^{o,h}(k) - \mu \frac{\partial E(k)}{\partial W^{o,h}(k)}, \quad (13)$$

где $E(k)$ – среднеквадратичная ошибка, а μ – показатель обучения.

Традиционный способ обучения предполагает заранее выбранное и зафиксированное малое значения показателя (от 0 до 1) в процессе обучения. Если значение показателя обучения слишком мало, то снижается скорость обучения, и наоборот, если значение показателя обучения слишком велико, скорость обучения может быть увеличена. При этом, при низкой скорости обучения вероятность сходимости нейронной сети крайне велика, в то время как, при высокой скорости обучения нейронная сеть может и не достигнуть сходимости.

В проведенных исследованиях предложено и изучено динамическое изменение показателя обучения, что обеспечит увеличение скорости обучения без потери сходимости. Так как нейронная сеть Элмана представляет собой рекуррентную сеть обратного распространения с двумя слоями, и принимая во внимание корреляцию ENN и временной последовательности, то для расчета показателя обучения предлагается использовать следующую формулу:

$$f = c \frac{\left(1 + \frac{1}{k}\right)^k}{e}, \quad (14)$$

где c – константа, а k – текущая итерация, при этом $f \in (0,1)$.

Таким образом, показатель обучения выбирается между уравнением (14) и значением по умолчанию. Алгоритм выбора показателя обучения представлен на Рисунке 4.

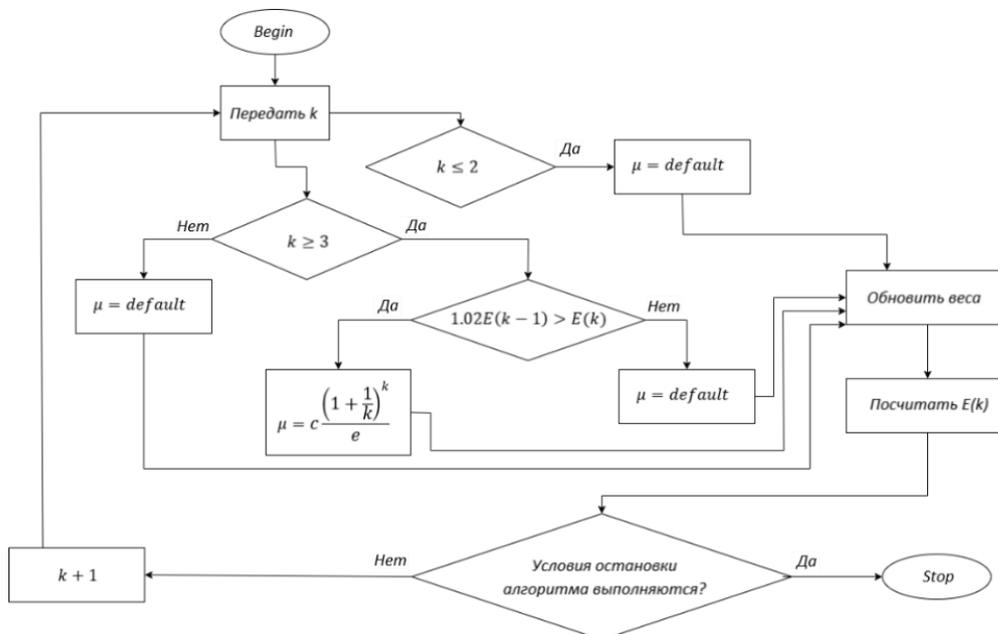


Рисунок 4 – Алгоритм расчета показателя обучения
 Figure 4 – Algorithm for calculating the learning rate

Таким образом, достигается динамическое обновление показателя обучения, что повышает эффективность обучения нейронной сети.

Модифицированная нейронная сеть Элмана используется для отслеживания траектории движения неголономного мобильного робота, кинематическая и

динамическая модели которого описаны выше (рис.2). В проводимом исследовании оценены три траектории движения: движения по прямой, по квадрату и по кругу. Чтобы проверить алгоритм обучения, оценивалось отклонение от заданной траектории, время обучения и количество итераций, за которые сеть была обучена. Значения параметров модели робота взяты из [1]: $M=0,65$ кг, $I=0,36$ кг*м², $L=0,105$ м и $r=0,033$ м.

В качестве набора для обучения использовалась конфигурация последовательно-параллельной и параллельной методики идентификации с модифицированной моделью рекуррентных нейронных сетей Элмана [8]. Это необходимо для ввода-вывода шаблона обучающих данных, чтобы предоставить достаточно информации о моделируемой кинематической и динамической модели мобильного робота. Для этого вводится входной гибридный сигнал активации всех интересующих режимов процесса (крутящий момент и скорость правого и левого колес). Входные сигналы представлены на Рисунке 5.

Сравнительный эксперимент проводился между классической нейронной сетью Элмана (ENN), модифицированной сетью Элмана (MENN) и PSO-алгоритмом (PSO-ENN).

Алгоритм PSO находит оптимальные решения определенных задач, «вспоминая» опыт каждой частицы и группы роя [10]. Это является одной из важнейших особенностей алгоритма PSO. В PSO-ENN пригодность частиц определяется как ошибка ENN, а цель обучения состоит в минимизации этой ошибки.

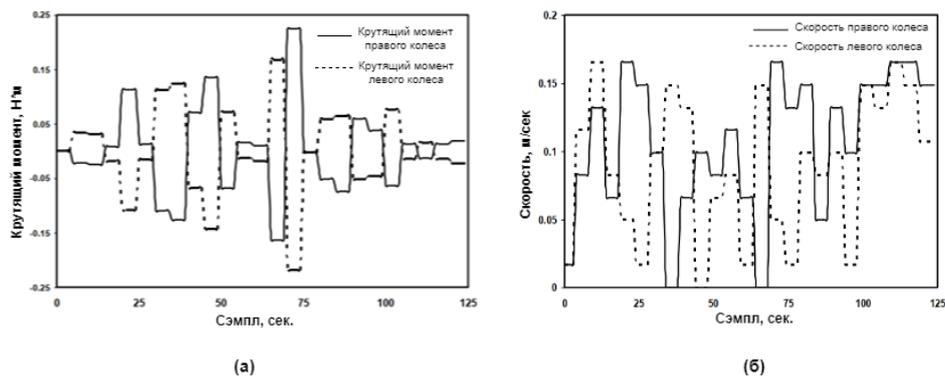


Рисунок 5 – Входные сигналы крутящего момента, используемые для активации нейронов модели мобильного робота: (а) крутящий момент правого и левого колес; и (б) скорость правого и левого колес

Figure 5 – The torque input signals used to activate the neurons of the mobile robot model: (a) the torque of the right and left wheels; and (b) the speed of the right and left wheels

Для каждой нейронной сети количество нейронов скрытого слоя установлено равным 15, максимальное количество итераций равно 10000, целевая ошибка обучения составляет 0:01, скорость обучения составляет 0:3. Для каждого алгоритма проводилось по пять испытаний.

Нейронная сеть написана на языке Python с использованием библиотек Keras и Tensorflow. Моделирование осуществлялось в среде моделирования CoppeliaSim, в которую была перенесена 3D-модель робота и окружения, созданные в Blender.

Результаты и обсуждение

На Рисунке 6 представлено сравнение трех алгоритмов по двум критериям: количество итераций, необходимых для обучения и среднее время обучения.

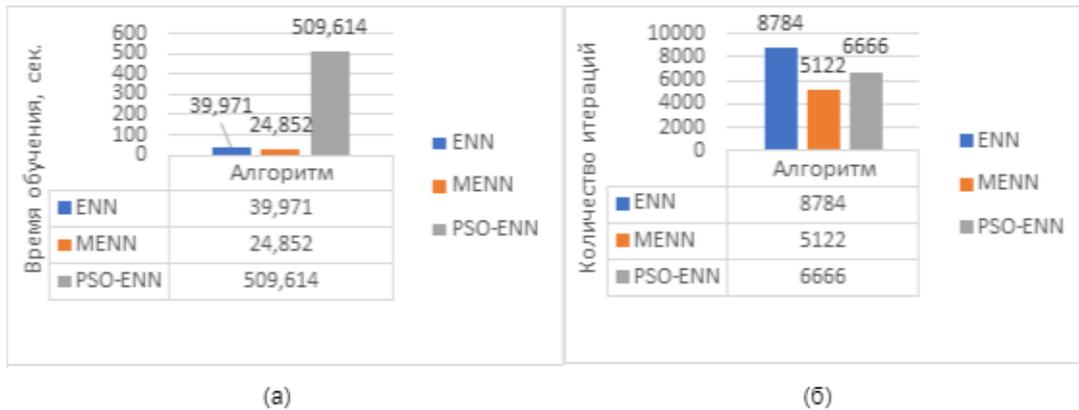


Рисунок 6 – Сравнение алгоритмов по критериям: (а) среднее время обучения и (б) количество итераций, потребовавшихся для обучения нейронной сети

Figure 6 – Comparison of algorithms by criteria: (a) average training time and (b) the number of iterations required to train the neural network

Как видно из Рисунка 6, модифицированный алгоритм Элмана с динамическим показателем обучения выполняется на 37,8% быстрее классического ENN и на 95,1 % быстрее PSO-ENN. При этом MENN снизил количество итераций, необходимых для обучения, в среднем, на 32,4 %. Значительно больше времени на обучение тратит PSO-ENN, при этом большее количество итераций необходимо ENN. На Рисунке 7 представлен график снижения ошибки (12) и количество итераций, потребовавшихся для этого.

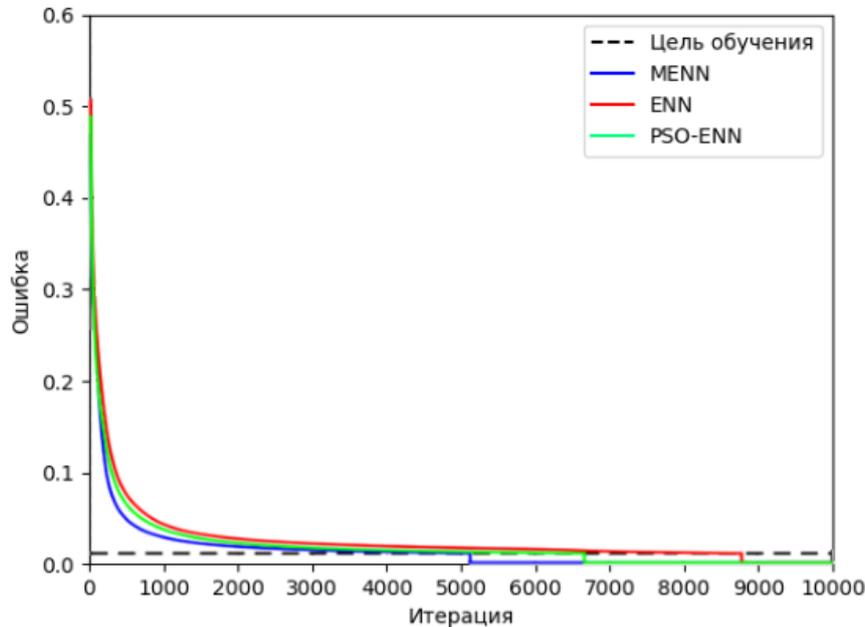


Рисунок 7 – График значения ошибки и итераций

Figure 7 – Graph of error value and iterations

Как видно из Рисунка 7, быстрее и эффективнее работает предлагаемый алгоритм, за ним идет PSO-ENN и только затем оригинальная ENN. Траектория движения робота, спрогнозированная модифицированной нейронной сетью Элмана представлена на Рисунке 8.

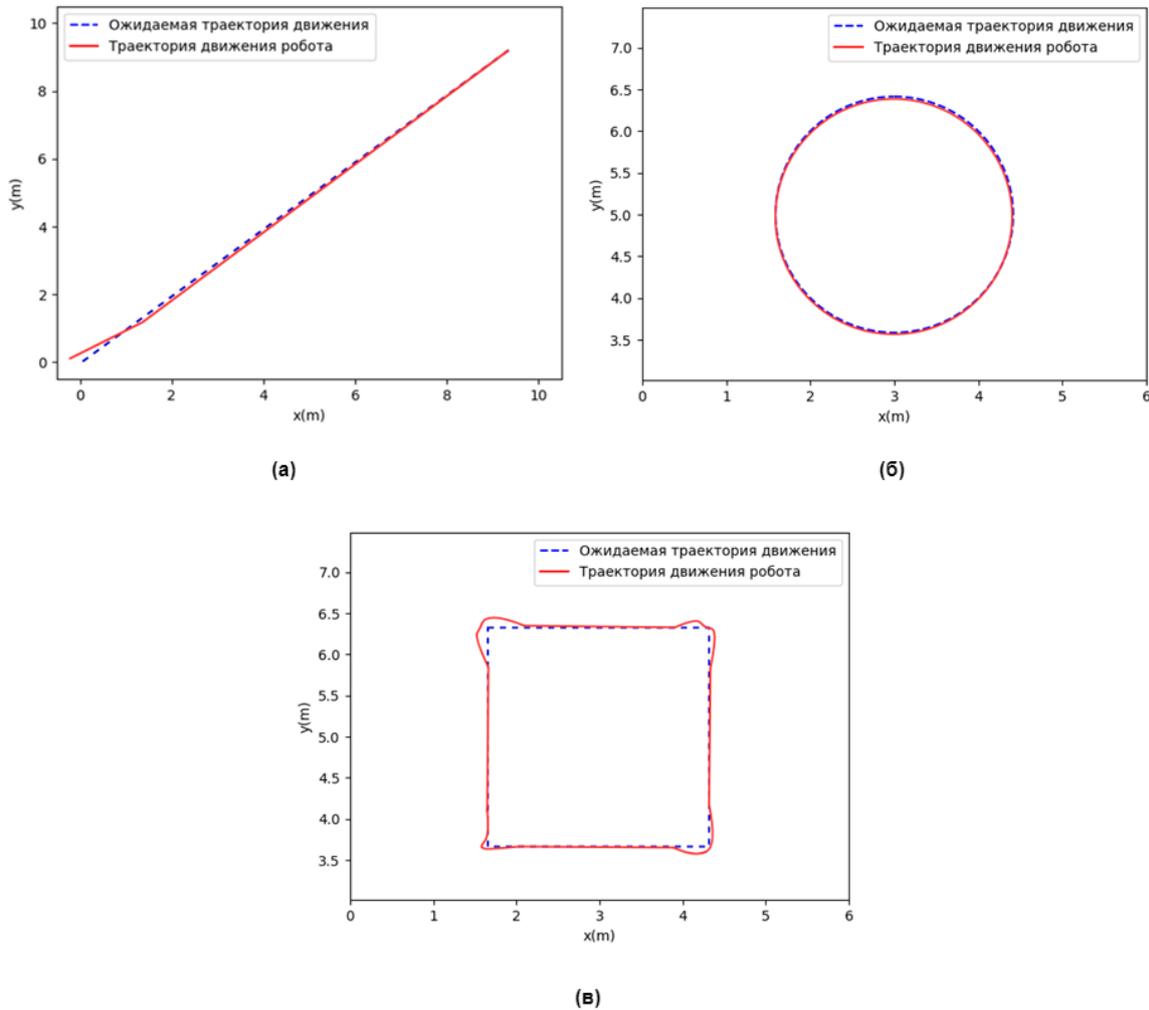


Рисунок 8 – Траектория движения робота, спрогнозированная модифицированной нейронной сетью Элмана с динамическим показателем обучения: (а) движение по прямой, (б) движение по окружности, (в) движение по квадрату

Figure 8 – The trajectory of the robot movement predicted by the modified Elman neural network with a dynamic learning rate: (a) movement along a straight line, (b) movement in a circle, (c) movement in a square

Как видно из Рисунка 8, наибольшую сложность для модифицированной нейронной сети Элмана представляет движение по квадрату с необходимостью соблюдения прямых углов. Именно на углах и происходит наибольшее отклонение от заданной траектории. В то время как, при движении по прямой и окружности существенных отклонений не наблюдается. Отклонение от заданной траектории движения составляет, в среднем, 3,1 %, 5,2 % и 15,8 % для движения по прямой, по кругу и по квадрату соответственно. Графики отклонения от ожидаемой траектории для каждого алгоритма для каждой траектории движения представлен на Рисунке 9.

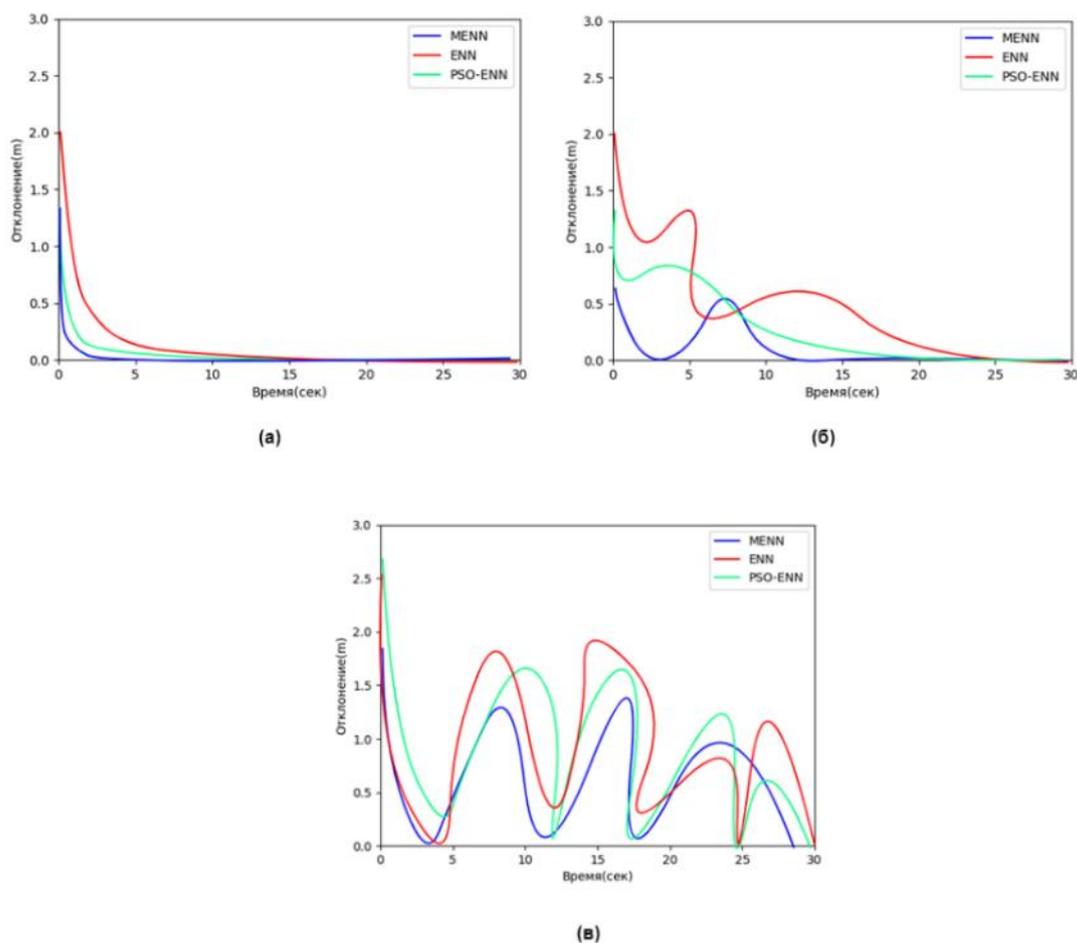


Рисунок 9 – Отклонение от ожидаемой траектории для каждого алгоритма: (а) движение по прямой, (б) движение по окружности, (в) движение по квадрату
Figure 9 – Deviation from the expected trajectory for each algorithm: (a) movement along a straight line, (b) movement in a circle, (c) movement in a square

Как видно из Рисунка 9, для каждого алгоритма на каждой из траекторий характерны однородные отклонения. При этом, при движении по квадрату, которое представлено на Рисунке 9 (в), наблюдается наибольшее отклонение (прямые углы квадрата) от заданной траектории для каждого алгоритма. Также стоит отметить, что большее начальное отклонение наблюдается у алгоритмов ENN и PSO-ENN, в то время как, модифицированный алгоритм Элмана отклоняется от заданной траектории меньше и быстрее снижает отклонение. Очевидно, что меньшее отклонение наблюдается при движении по прямой для каждого алгоритма, как видно из Рисунка 9 (а). При этом отклонение от заданной траектории происходит только в начале движения, а затем сводится к нулю для каждого алгоритма. При этом наименьшее начальное отклонение наблюдается у алгоритма PSO-ENN. При движении по окружности модифицированный алгоритм Элмана имеет меньше отклонение от заданной траектории, чем алгоритмы ENN и PSO-ENN, как видно из Рисунка 9 (б). Таким образом, модифицированный алгоритм Элмана, в среднем, на 15,4 % меньше отклоняется от траектории движения по прямой, на 31,5 % – от траектории движения по кругу и на 25,3 % – от траектории движения по квадрату, чем PSO-ENN и ENN.

Относительная погрешность измерений для каждого алгоритма (ENN, MENN, PSO-ENN) в каждой группе измерений (время обучения, количество итераций, среднее

отклонение от заданной траектории при движении: по прямой, по окружности, по квадрату) представлена на Рисунке 10. Количество проведенных испытаний – 5, уровень надежности – 95 %, коэффициент Стьюдента – 2,78.

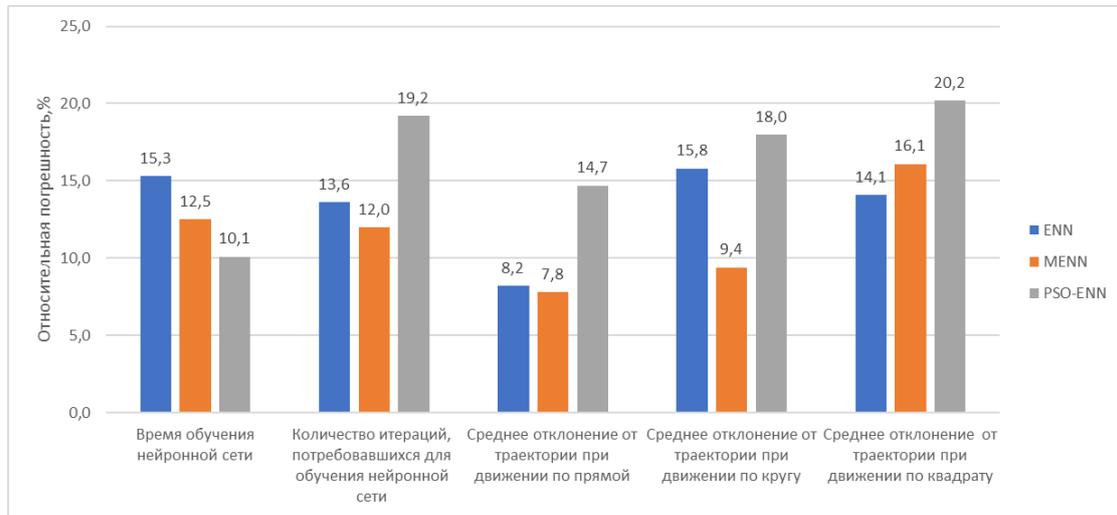


Рисунок 10 – Относительная погрешность измерений для каждого алгоритма в каждой группе измерений

Figure 10 – Relative measurement error for each algorithm in each group of measurements

Как видно из Рисунка 10, относительная погрешность измерений варьируется в диапазоне от 7,8 % до 20,2 %. При этом, наименьшая погрешность у алгоритма MENN в группе среднего отклонения от траектории при движении по прямой, а наибольшая – у алгоритма PSO-ENN в группе среднего отклонения от траектории при движении по квадрату. На Рисунке 11 представлена средняя относительная погрешность для каждой группы измерений, что отражено на Рисунке 11 (а), и для каждого алгоритма, как видно из Рисунка 11 (б).

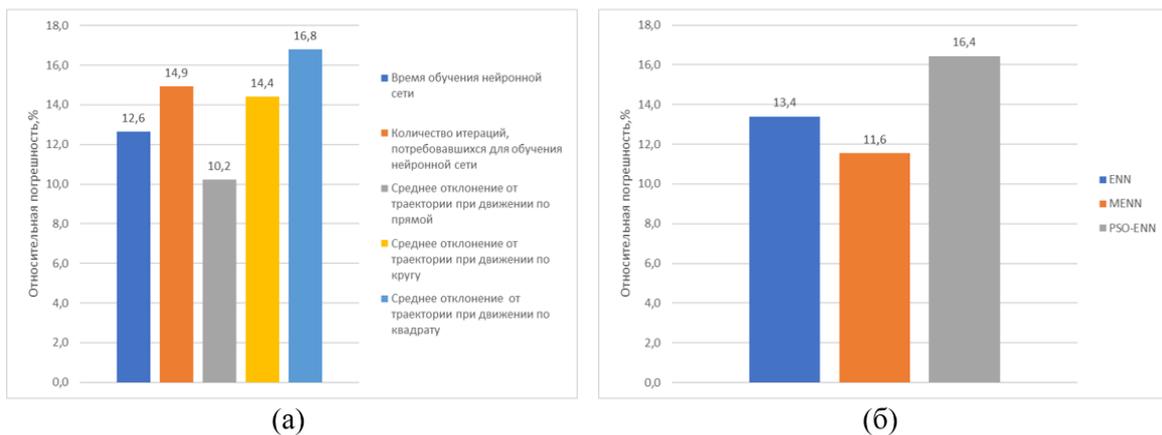


Рисунок 11 – Средняя относительная погрешность измерений для: (а) каждой группы измерений; (б) для каждого алгоритма

Figure 11 – Average relative measurement error for: (a) each group of measurements; (b) for each algorithm

Как видно из Рисунка 11, наименьшая средняя относительная погрешность (10,2 %) наблюдается в группе измерений среднего отклонения от траектории при движении по прямой, а наибольшая (16,8 %) – в группе измерений среднего отклонения

от траектории при движении по квадрату. При этом алгоритм MENN показал наименьшую среднюю относительную погрешность (11,6 %), а алгоритм PSO-ENN – наибольшую (16,4 %).

Заключение

Таким образом, предлагаемый алгоритм расчета показателя обучения нейронной сети Элмана способствует повышению скорости обучения при снижении количества итераций. При этом модифицированная нейронная сеть Элмана, в целом, более эффективна в отслеживании и прогнозировании траектории движения неголономного трехколесного мобильного робота при движении по прямой, окружности и квадрату.

В дальнейшем планируется использовать модифицированную нейронную сеть Элмана в качестве модуля адаптивного автономного контроллера для определения ориентации и прогнозирования положения робота.

СПИСОК ИСТОЧНИКОВ

1. Su K.H., Chen Y.Y., Su S.F. Design of neural-fuzzy-based controller for two autonomously driven wheeled robot. *Neurocomputing*. 2015; 73:2478–2488.
2. Березина В.А., Мезенцева О.С., Ганьшин К.Ю. Гибридная нейроэволюция как способ обучения нейронных сетей на примере решения задачи поиска пути в лабиринте. *Моделирование, оптимизация и информационные технологии*. 2021;9(3). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1012>. DOI: 10.26102/2310-6018/2021.34.3.014 (дата обращения: 26.04.2022).
3. Lucas R., Oliveira R. M., Nascimento C. B., Kaster M. S. Performance analysis of an adaptive Gaussian nonlinear PID control applied to a step-down CC-CC converter. *IEEE 24th International Symposium on Industrial Electronics (ISIE)*. 2015;1:1022–1026.
4. Li Z., Yang C., Su C., Deng J., Zhang W. Vision-Based Model Predictive Control for Steering of a Nonholonomic Mobile Robot. *IEEE Transactions on Control Systems Technology*. 2019;24(2):553–564.
5. Suprpto B.Y., Mustaqim A., Wahab W., Kusumoputro B. Modified elman recurrent neural network for attitude and altitude control of heavy-lift hexacopter. *15th International Conference on Quality in Research (QiR): International Symposium on Electrical and Computer Engineering*. 2017;1:309–314.
6. He W. Adaptive neural network control of an uncertain robot with fullstate constraints. *IEEE Transactions on Cybernetics*. 2016;46(3):620–629.
7. Al-Jamali N. A., Al-Raweshidy H. S. Modified Elman Spike Neural Network for Identification and Control of Dynamic System. *IEEE Access*, vol. 2020;8:61246–61254.
8. Li D., Liu Y., Tong S., Chen C. L. Approximation-Based Adaptive Neural Tracking Control of Nonlinear MIMO Unknown Time-Varying Delay Systems with Full State Constraints. *IEEE Transactions on Cybernetics*. 2017;47(10):3100–3109.
9. Deng L., Seethaler R. J., Chen Y., Yang P., Cheng Q. Modified Elman neural network based neural adaptive inverse control of rate-dependent hysteresis. *International Joint Conference on Neural Networks (IJCNN)*. 2016;1:2366–2373.
10. Wang S., Zhang Y., Dong Z., Du S., Ji G. Feed-forward neural network optimized by hybridization of PSO and ABC for abnormal brain detection. *International Journal of Imaging Systems & Technology*. 2015;25(2):153–164.

REFERENCES

1. Su K.H., Chen Y.Y., Su S.F. Design of neural-fuzzy-based controller for two autonomously driven wheeled robot. *Neurocomputing*. 2015; 73:2478–2488.

2. Berezina V.A., Mezentseva O.S., Ganshin K.Y. Hybrid neuroevolution as a way to train neural networks by the example to solve the maze problem. *Modeling, Optimization and Information Technology*. 2021;9(3). Available by: <https://moitvivr.ru/ru/journal/pdf?id=1012>. DOI: 10.26102/2310-6018/2021.34.3.014 (accessed 26.04.2022). (In Russ.)
3. Lucas R., Oliveira R. M., Nascimento C. B., Kaster M. S. Performance analysis of an adaptive Gaussian nonlinear PID control applied to a step-down CC-CC converter. *IEEE 24th International Symposium on Industrial Electronics (ISIE)*. 2015;1:1022–1026.
4. Li Z., Yang C., Su C., Deng J., Zhang W. Vision-Based Model Predictive Control for Steering of a Nonholonomic Mobile Robot. *IEEE Transactions on Control Systems Technology*. 2019;24(2):553–564.
5. Suprpto B.Y., Mustaqim A., Wahab W., Kusumoputro B. Modified elman recurrent neural network for attitude and altitude control of heavy-lift hexacopter. *15th International Conference on Quality in Research (QiR): International Symposium on Electrical and Computer Engineering*. 2017;1:309–314.
6. He W. Adaptive neural network control of an uncertain robot with fullstate constraints. *IEEE Transactions on Cybernetics*. 2016;46(3):620–629.
7. Al-Jamali N. A., Al-Rawashidy H. S. Modified Elman Spike Neural Network for Identification and Control of Dynamic System. *IEEE Access*, vol. 2020;8:61246–61254.
8. Li D., Liu Y., Tong S., Chen C. L. Approximation-Based Adaptive Neural Tracking Control of Nonlinear MIMO Unknown Time-Varying Delay Systems with Full State Constraints. *IEEE Transactions on Cybernetics*. 2017;47(10):3100–3109.
9. Deng L., Seethaler R. J., Chen Y., Yang P., Cheng Q. Modified Elman neural network based neural adaptive inverse control of rate-dependent hysteresis. *International Joint Conference on Neural Networks (IJCNN)*. 2016;1:2366–2373.
10. Wang S., Zhang Y., Dong Z., Du S., Ji G. Feed-forward neural network optimized by hybridization of PSO and ABC for abnormal brain detection. *International Journal of Imaging Systems & Technology*. 2015;25(2):153–164.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Березина Виктория Андреевна, аспирантка, Северо-Кавказский федеральный университет, Ставрополь, Российская Федерация.

e-mail: BerezinaVA@yandex.ru

Victoria A. Berezina, Post-Graduate Student, North-Caucasus Federal University, Stavropol, Russian Federation.

Мезенцева Оксана Станиславовна, кандидат физико-математических наук, Профессор кафедры информационных систем и технологий, Северо-Кавказский федеральный университет, Ставрополь, Российская Федерация.

e-mail: omezentceva@ncfu.ru

ORCID: [0000-0001-5503-1056](https://orcid.org/0000-0001-5503-1056)

Oksana S. Mezentseva, Candidate of Physical and Mathematical Sciences, Professor of the Department of Information Systems and Technologies, North-Caucasus Federal University, Stavropol, Russian Federation.

Мезенцев Дмитрий Викторович, старший преподаватель кафедры информационных систем и технологий, Северо-Кавказский федеральный университет, Ставрополь, Российская Федерация.

e-mail: dmezentcev@ncfu.ru

Dmitry V. Mezentsev, Senior Lecturer of the Department of Information Systems and Technologies, North-Caucasus Federal University, Stavropol, Russian Federation.

*Статья поступила в редакцию 01.06.2022; одобрена после рецензирования 06.07.2022;
принята к публикации 15.07.2022.*

*The article was submitted 01.06.2022; approved after reviewing 06.07.2022;
accepted for publication 15.07.2022.*