

Рубрика 2. НАУЧНЫЕ И ПРАКТИЧЕСКИЕ РАЗРАБОТКИ  
Направление – Электротехнические комплексы и системы

<https://doi.org/10.17816/transsyst634127>

© А.А. Лисов

Южно-Уральский государственный университет  
(Челябинск, Россия)

## РАЗРАБОТКА СИСТЕМЫ ЭЛЕКТРОННОГО ДИФФЕРЕНЦИАЛА ДЛЯ ЭЛЕКТРОМОБИЛЕЙ НА ОСНОВЕ НЕЙРОСЕТИ ГЛУБОКОГО ОБУЧЕНИЯ

**Обоснование.** В состав большинства современных автомобилей входит трансмиссия, состоящая из двигателя внутреннего сгорания (ДВС), передающего усилие через коробку передач к валу дифференциала, который передает крутящий момент на колёса. В случае с электротранспортом электродвигатели могут быть прикреплены непосредственно к колесам через понижающий редуктор, и при правильной системе управления автомобиль может передавать различный крутящий момент на колеса с каждой стороны автомобиля для реализации высокой управляемости. Такая система носит название – электронный дифференциал, его реализация может быть как очень простой, основанной на модели Аккермана-Жантана, которая не способна полноценно заменить простой механический дифференциал, так и основана на механизмах робастного управления с рысканьем по моменту. Последний метод требует довольно сложную систему управления и дорогостоящие датчики. Но есть и третий подход – использование нейронных сетей для управления скоростью электротранспорта.

**Цель.** Предоставить материалы и программное обеспечение для реализации электронного дифференциала, основанного на искусственных нейронных сетях, для расширения спектра решений проблемы управления несколькими приводами электроавтомобилей и иного электротранспорта.

**Материалы и методы.** Нейронная сеть учитывает совокупность аспектов, которые влияют или не влияют на работу электронного дифференциала путем подбора специальных коэффициентов – весов для нейронов внутри сети. В качестве основы для получения данных используются специальные карты трасс на основе переходной кривой.

**Результаты.** Результаты теста позволили получить точность прогнозирования равную 0,7273, среднеквадратичное отклонение для тренировочной выборки равное 0,064, а для тестовой выборки равное 0,065.

**Заключение.** Решение использовать нейросетевое управление электроприводом имеет право быть хорошим вариантом на замену иным алгоритмам. Кроме того, поскольку нейронные сети имеют большую гибкость и обучаемость, то на базе данного дифференциала можно также реализовать дополнительные функции помощи водителю, такие как ESP, ABS, круиз-контроль и др.

**Ключевые слова:** электромобили; электронный дифференциал; система управления; нейронные сети.

### Как цитировать:

Лисов А.А. Разработка системы электронного дифференциала для электромобилей на основе нейросети глубокого обучения // Инновационные транспортные системы и технологии. 2024. Т. 10. № 3. С. 351–367. doi: 10.17816/transsyst634127

Section 2. SCIENTIFIC AND PRACTICAL RESEARCH

Subject – Electrotechnical complexes and systems

© **A.A. Lisov**

South Ural State University

(Chelyabinsk, Russia)

## DEVELOPMENT OF AN ELECTRONIC DIFFERENTIAL SYSTEM FOR ELECTRIC VEHICLES BASED ON DEEP NEURAL NETWORK

**Background.** Modern cars typically use a transmission system where an internal combustion engine transmits force through a gearbox to a differential shaft, which then transmits torque to the wheels. In electric vehicles, however, electric motors can be attached directly to the wheels through a reduction gearbox. With a right control system, these vehicles can apply different torque to the wheels on each side of the vehicle, significantly enhancing handling. This set-up is known as an electronic differential. Its implementation can vary from simple, using the Ackerman–Jeantand model, which cannot fully replace a simple mechanical differential, to complex systems employing robust control mechanisms with yaw torque. The latter method requires a rather complex control system and expensive sensors. A third –innovative approach involves using neural networks to control electric vehicle speeds.

**Aim.** The aim is to provide materials and software for implementing an electronic differential using artificial neural networks to expand the solutions available for controlling multiple electric drives in various electric vehicles.

**Materials and Methods.** The neural network considers multiple factors affecting the operation of electronic differential by selecting special coefficients, weights, to neurons within the network. As a basis for obtaining data, special route maps based on the transition curve will be used.

**Results.** Testing yielded a prediction accuracy of 0.7273, with a standard deviation of 0.064 for the training set and 0.065 for the testing set.

**Conclusion.** Employing neural networks for controlling electric drives is a promising alternative to traditional algorithms. Owing to their flexibility, these neural networks can also implement additional driver assistance functions, such as ESP, ABS, cruise control, etc.

**Keywords:** electric vehicles; electronic differential; control system; neural networks.

### To cite this article:

Lisov AA. Development of an electronic differential system for electric vehicles based on deep neural network. *Modern Transportation Systems and Technologies*.

2024;10(3):351–367. doi: 10.17816/transsyst634127

## ВВЕДЕНИЕ

На сегодняшний день наблюдается устойчивая тенденция к развитию электротранспорта по всему миру. Обычные автомобили в своём составе имеют трансмиссию, состоящую из двигателя внутреннего сгорания (ДВС), передающего усилие через коробку передач к валу дифференциала, который, который в свою очередь, передает крутящий момент на колёса. В случае с электротранспортом электродвигатели могут быть прикреплены непосредственно к колесам через понижающий редуктор, и, при правильной системе управления, автомобиль может передавать различные крутящие моменты на колеса с каждой стороны автомобиля для реализации высокой управляемости [1], либо использовать классическую схему с одним тяговым двигателем и дифференциалом.

Реализация электронного дифференциала может быть разнообразной и иметь несколько вариантов конфигураций [2]. Однако на практике, следует выделить 2 наиболее оптимальных варианта: полностью полноприводный автомобиль с 4-мя независимыми двигателями и два независимых двигателя сзади. В данной статье внимание будет уделено конфигурации автомобиля с двумя независимыми двигателями сзади, структурная схема которого изображена на Рис. 1.

Такая конфигурация позволяет достичь хороших динамических характеристик и управляемости и сложной системы подвески (независимая и полунезависимая) для распределения крутящего момента как это приходится делать в случае применения переднего привода [3].

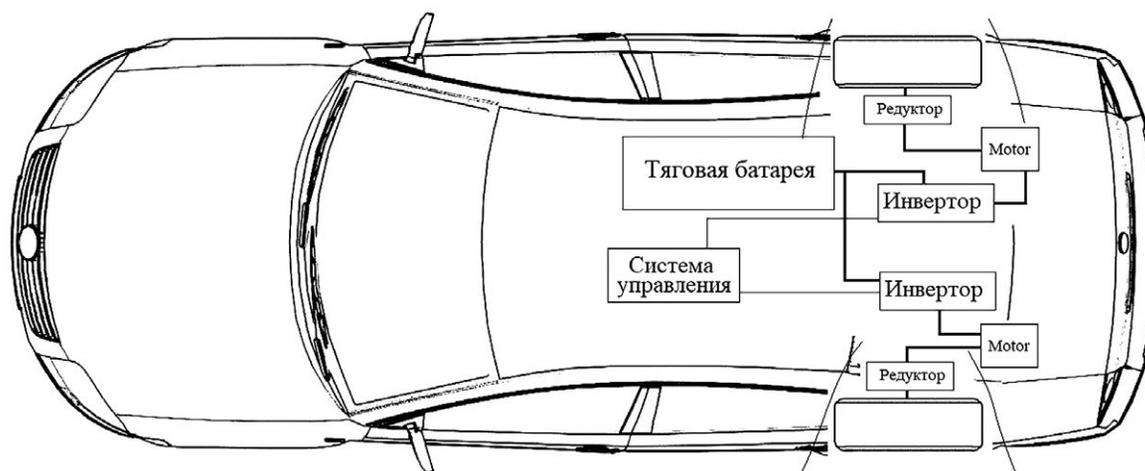


Рис. 1. Конфигурация трансмиссии с 2-мя независимыми двигателями сзади

Fig. 1. Transmission configuration with 2 independent motors at the rear

Наиболее часто используемый вид электронного дифференциала – модель Аккермана-Жантана [4]. Эта модель была первоначально создана Рудольфом Аккерманом в XIX веке и служит для установления связи между скоростями вращения внутреннего и внешнего колес автомобиля во время маневров. Стоит отметить, что указанная модель при этом не учитывает множество аспектов реального движения автомобиля на значительной скорости (вращение вокруг своей оси, поведение шин, состояние дорожного покрытия и т.д.) [5]. Для решения поставленной задачи был разработан, например, метод робастного управления [6], основанной на двухступенной схеме прямого управления моментом рыскания. Тем не менее, модель в этом случае получается довольно громоздкая и требует наличия дорогостоящих датчиков и систем контроля. Однако, существует ещё один известный способ – использование нейронных сетей (НС, NN), который впервые был предложен в [7]. Вместе с тем, указанная концепция не получила должного развития из-за необходимости придумать уникальный метод для обучения НС, что было успешно реализовано в рамках диссертационной работы и показано в данном исследовании.

НС в виду своей гибкости может учитывать все ранее перечисленные аспекты, влияющие на характер движения транспортного средства и при этом она не будет использовать сложные алгоритмы и формулы как алгоритмах робастного управления. Сейчас концепция нейронных сетей стала активной областью исследований в области силовой электроники и приводов двигателей. Из-за их адаптивных способностей в процессе обучения, применение для идентификации систем и динамики управления стало многообещающей альтернативой управлению процессами [8, 9]. НС могут применяться для управления и идентификации нелинейных систем, поскольку они аппроксимируют любую желаемую степень точности с помощью широкого спектра нелинейных моделей [10, 11].

В настоящей статье предлагается дальнейшее развитие и исследование данного подхода управления тяговым электроприводом электромобилей. Развитие представляет из себя разработку универсальной системы сбора и обработки информации с датчиков для последующего обучения нейронной сети, которые ранее не рассматривались в иных исследованиях.

## 1. ПРИНЦИП СБОРА ДАННЫХ

Электронная система дифференциального управления на основе нейронной сети с алгоритмом обратного распространения ошибки

является системой, где результатом работы является предсказание, основанное на обучении сети на результатах эксперимента. Нейронная сеть учитывает совокупность аспектов, которые влияют или не влияют на работу электронного дифференциала путём подбора специальных коэффициентов – весов для нейронов внутри сети.

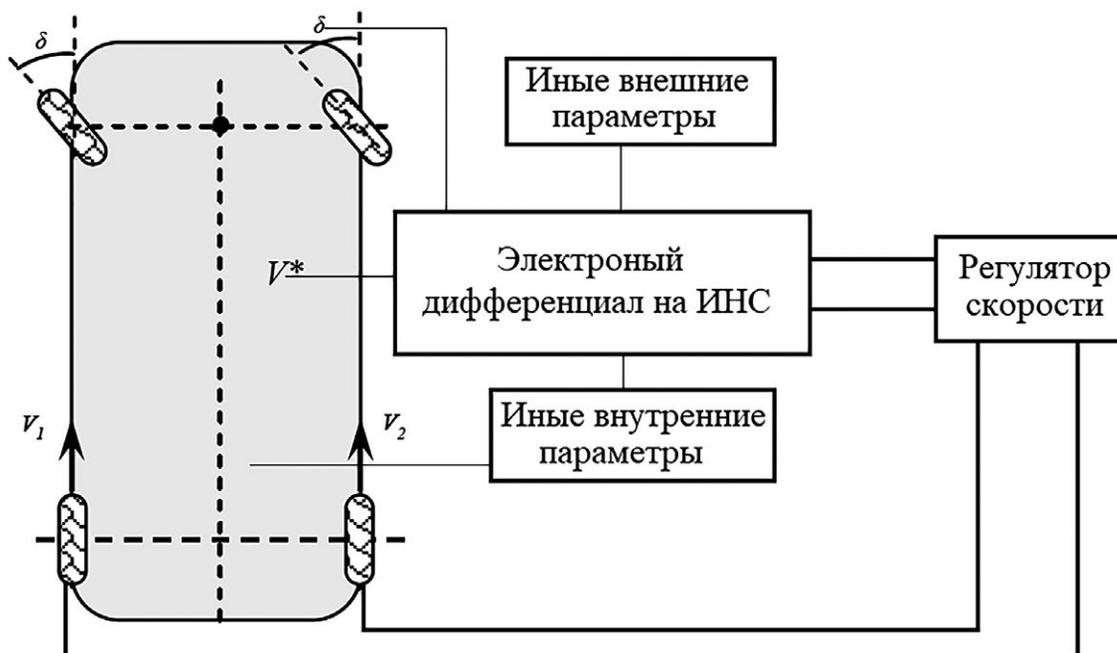
На малых скоростях для определения траектории движения автомобиля широко используется ранее упомянутая модель Аккермана и Жеантана. Однако, как уже говорилось у данной модели есть ограничение – она не учитывает влияние центробежной силы, характер поведения шин, погодные условия и привычки водителя. Все эти аспекты можно учесть с помощью НС, что наглядно было подтверждено серией исследований [12–16].

Вышеупомянутые статьи были доработаны до более применительного на практике вида, путём разработки ПО для обучения НС на экспериментальных данных, ПО для сбора и обработки информации с датчиков посредством ПК и микроконтроллера, а также ряда программ для исследования влияния гиперпараметров на конечную точность прогнозирования сети и иных вспомогательных скриптов. Кроме того, была разработана функциональная схема электропривода, являющаяся основой для принципиальной схемы модели электромобиля для сбора данных. Стоит отметить, что для управления скоростью электропривода также можно увидеть применение НС [17–19]. В рамках данной статьи будет рассмотрен общий принцип построения системы для сбора показаний датчиков скорости, гироскопа, акселерометра и угла поворота рулевой рейки, а также результаты тестирования точности прогнозирования разработанной нейронной сети.

НС получает значение скорости из линейной модели, анализирует внешние параметры и корректирует скорость привода таким образом, чтобы достичь максимальной эффективности, общая структура электронной дифференциальной системы для сбора информации представлена на Рис. 2.

### **Создание переходных кривых как основы для получения датасета**

В качестве основы для получения данных будут использованы специальные карты трасс на основе переходной кривой. Переходная кривая – это плавное сглаживание перехода между двумя прямыми участками дороги или железной дороги и изгибами. Она применяется для снижения резкости изменений направления движения



**Рис. 2.** Структура электронной дифференциальной системы с использованием нейронной сети

**Fig. 2.** Structure of an electronic differential system using a neural network

и обеспечения комфортного перемещения транспортных средств и пассажиров.

Переходные кривые обычно имеют форму дуги окружности или спиральной линии, которые соединяют прямые участки с изгибами. Эти кривые строятся таким образом, чтобы обеспечить плавный переход от прямолинейного движения к движению по изгибу без резких ускорений или замедлений. Использование переходных кривых помогает уменьшить риски аварийного торможения или ускорения на изломах дороги, а также повысить безопасность и комфортность движения на дорогах и железнодорожных путях.

Поскольку данные кривые используются при построении поворотов на реальных дорогах целесообразно использовать эти построения и формулы и для модели автомобиля в соответствующем масштабе. Построение круговой кривой показано на Рис. 3. Сокращения на нём имеют следующие определения: ВСТ / ЕСТ – beginning / end of the curve turn; ВСС / ЕСС – beginning / end of a circular curve.

На Рис. 3 представлены следующие геометрические элементы закругления: угол –  $\alpha$ , радиус –  $R$ , кривая –  $K$ , тангенс –  $T$ , биссектриса –  $B$ , домер –  $T_0$  и длина переходных кривых  $L$ . Домер используется для

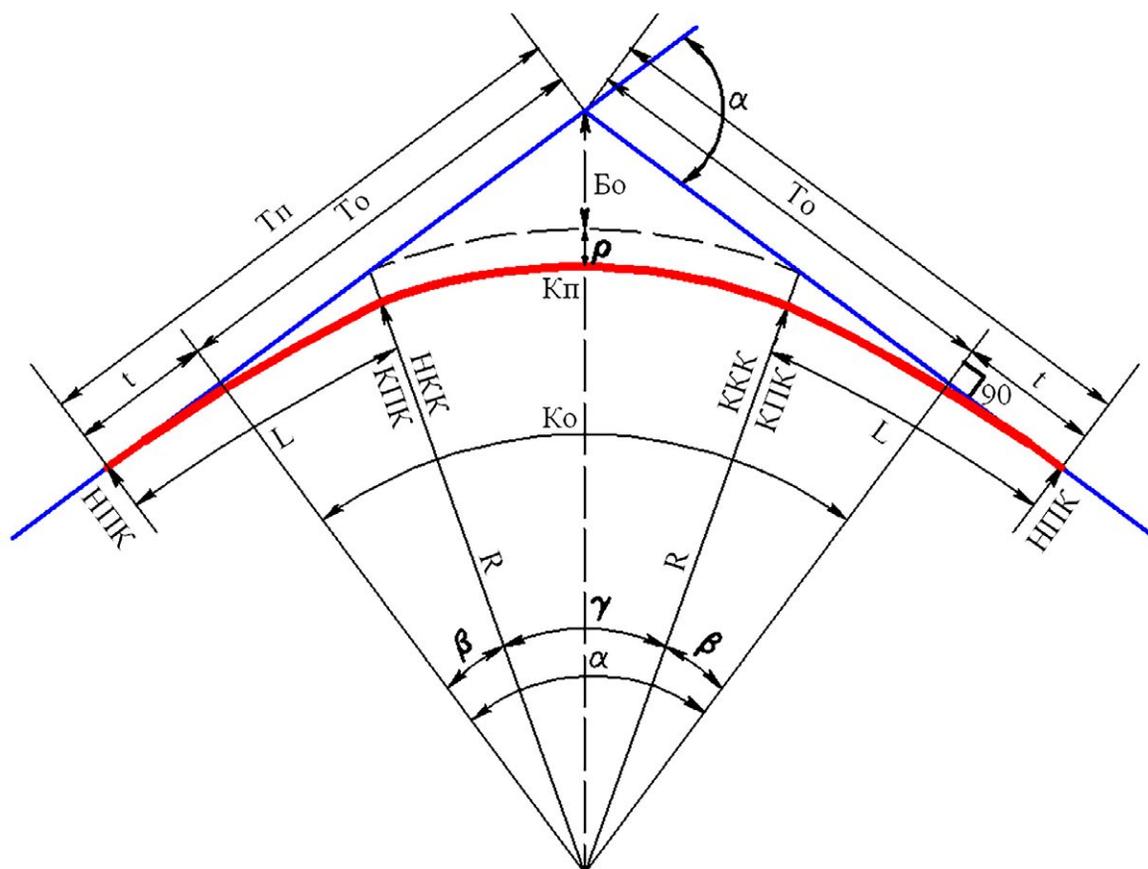


Рис. 3. Схема круговой кривой

Fig. 3. Circular curve diagram

обозначения части переходной кривой, которая находится между прямым участком дороги или железной дороги и самой кривой. Домер является частью переходной кривой, где происходит постепенное изменение радиуса кривизны от значения, характерного для прямолинейного участка, к значению, соответствующему кривизне изгиба.

Иными словами, домер – это участок переходной кривой, на котором радиус кривизны плавно изменяется от нуля (для прямого участка) до радиуса кривизны кривой. Этот участок обеспечивает плавный переход между прямолинейным и криволинейным движением, что помогает уменьшить воздействие центробежных сил на транспортное средство и обеспечивает более комфортное и безопасное движение.

Расстояние от вершины угла до начала кривой ( $T$ ) вычисляется следующим образом:

$$T = tg \frac{\alpha}{2} \quad (1)$$

Расстояние от начала кривой до конца кривой ( $K$ ) можно вычислить по формуле:

$$K = \frac{\pi R \cdot \alpha}{180^\circ} \quad (2)$$

Расстояние от вершины угла поворота до середины кривой ( $B$ ) рассчитывается согласно:

$$B = R \cdot \left( \sec \frac{\alpha}{2} - 1 \right) = R \left( \frac{1}{\cos \left( \frac{\alpha}{2} \right)} - 1 \right) \quad (3)$$

Домер ( $T_0$ ) вычисляется в соответствии с формулой:

$$T_0 = 2 \cdot T - K \quad (4)$$

Длина переходных кривых зависит от  $R$  и может быть определена по формуле:

$$L = \frac{v^3}{47 \cdot R \cdot \gamma} \quad (5)$$

где  $v$  – скорость транспортного средства; а  $\gamma$  – величина нарастания центробежного ускорения (обычно принимается в диапазоне  $[0,3;1]$  м/с<sup>2</sup>).

## 2. СОЗДАНИЕ ДАТАСЕТА ДЛЯ ОБУЧЕНИЯ НС

На Рис. 4 приведена схема вычисления отклонения для обучения нейронной сети для электронного дифференциала. Принцип состоит в том, чтобы заранее расчертить на карте поворотов идеальные кривые (красная траектория на Рис. 4), к которым нужно стремиться при управлении приводами при помощи НС. При проведении экспериментов на тяговые приводы подаются различные вариации скорости вращения, чтобы получить иную траекторию движения (синяя на Рис. 4), данные с датчиков и самое главное величину отклонения от идеальной траектории в градусах, именно эти данные станут основой для датасета. При штатной работе электронной дифференциальной системы отклонение будет автоматически задаваться нулём.

Сбор данных происходит в полуавтоматическом режиме – оператор задает момент для начала и окончания процесса, а также дает команду на экспорт данных в excel для дальнейшей обработки. Датасет состоит

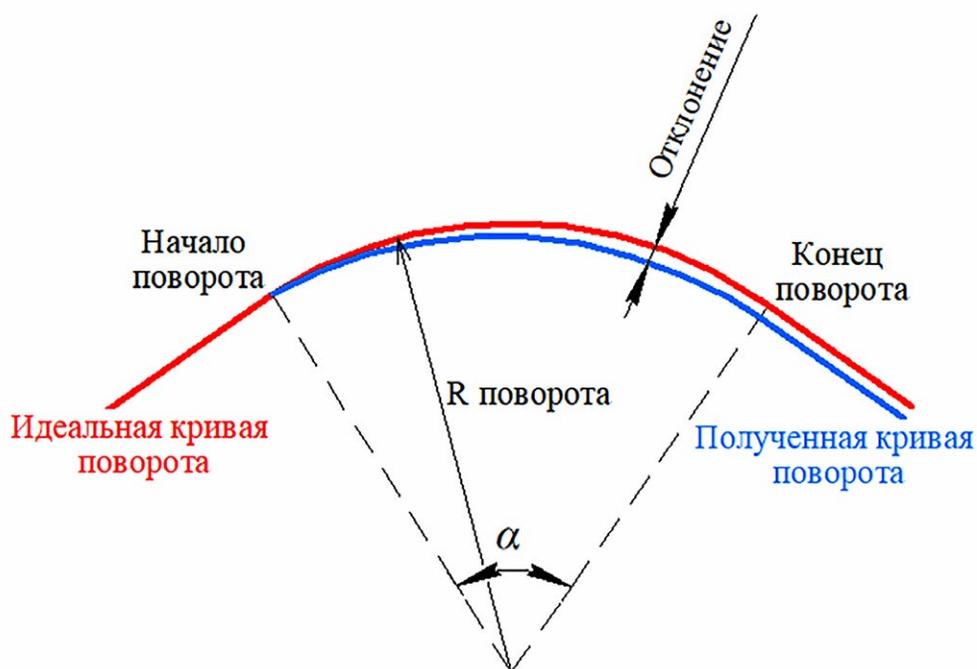


Рис. 4. Принцип вычисления отклонения для тренировки ИНС

Fig. 4. Principle of calculating the deviation for ANN training

из 217 отфильтрованных замеров с датчиков. После экспорта данные масштабируются в диапазон  $[-1;1]$  для более корректного вычисления градиентов при обучении НС. Все данные будут опубликованы на GitHub автора работы (пользователь: AnLiMan, репозиторий: Electronics\_Differential\_System).

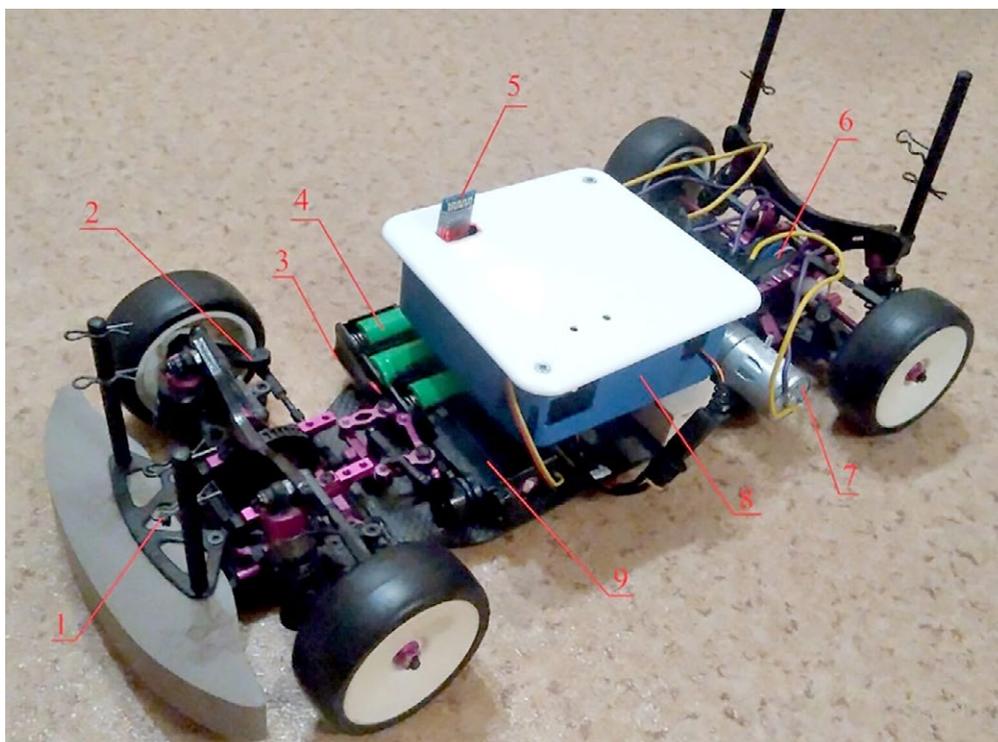
## РЕЗУЛЬТАТЫ

Как говорилось ранее, методика сбора данных для нейросети предполагает наличие специальной карты идеальных кривых вращения. На Рис. 6 показано фото этой карты поворотов. Карта выполнена на листах миллиметровой масштабной-координатной бумаге для упрощения расчетов отклонений. Модель электромобиля (Рис. 7) движется по этому полю и отмечает пройденную траекторию ручкой со стираемыми чернилами (можно и карандашом), также во время движения на компьютер поступают данные с датчиков.

На Рис. 6 приняты следующие обозначения: 1 – Отверстие для пишущего устройства для записи траектории; 2 – Передние тяги для поворота колёс; 3 – BMS тяговой батареи; 4 – Тяговая батарея; 5 – Bluetooth-модуль для связи с ПК; 6 – Спроектированный механизм



**Рис. 5.** Карты поворотов для сбора данных  
**Fig. 5.** Maps of turns for data collection



**Рис. 6.** Модель электромобиля в сборе  
**Fig. 6.** Complete electric vehicle model

передачи крутящего момента; 7 – Тяговые двигатели; 8 – Корпус системы управления с макетной платой внутри; 9 – Сервопривод для поворота тяг.

Графики процесса обучения функции потерь (Рис. 7) и точности прогнозирования (Рис. 8) приведены ниже. Анализ графических результатов позволяет сделать вывод о неплохой точности прогноза даже при условии небольшого количества исходных данных для обучения, что позволило получить следующие точность прогнозирования равную 0,7273, среднеквадратичное отклонение (Root Mean Square Error, RMSE) для тренировочной выборки равное 0,064, а для тестовой выборки равное 0,065.

Среднее время на расчёт составило  $0,10513 \pm 5\%$  секунд при задании отдельными массивами (пакетами) с каждым новым вызовом функции предсказания. С единоразовым вывозом функции предсказания для тестовой выборки из 22 пакетов составило  $0,02776 \pm 5\%$  секунды.

На Рис. 9 приведены результаты теста точности прогнозирования НС на тестовой выборке из 22 пакетов. Синяя линия ( $V_1$ ) истинное значение из датасета, а зеленая линия предсказанное НС значение  $V_1$ . Оранжевая линия  $V_2$  реальное значение, а красная – предсказанное значение  $V_2$ . Как видно из Рис. 9. НС показывает неплохие результаты даже при столь небольшом размере датасета, т.к. по крайней мере предсказания стремятся к своим референсным значениям.

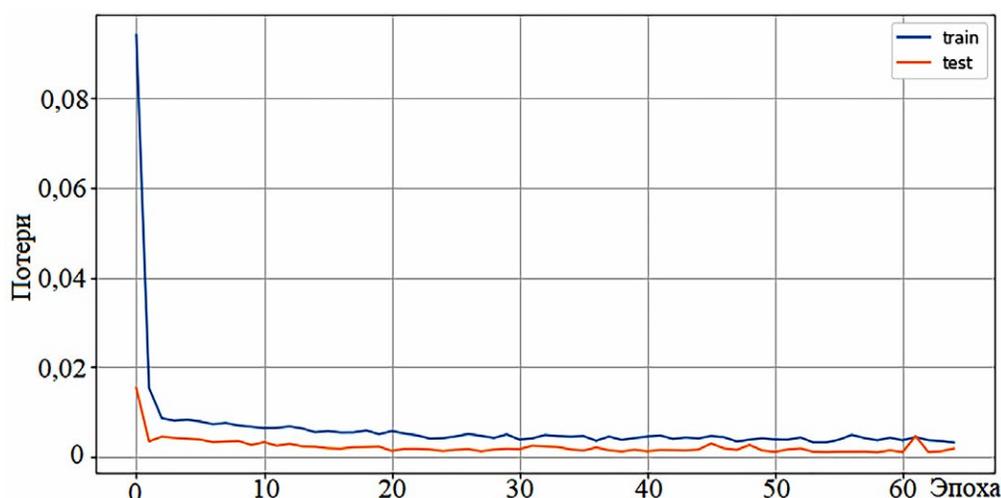


Рис. 7. График потерь (loss) в процессе обучения ИНС

Fig. 7. Graph of losses during ANN training

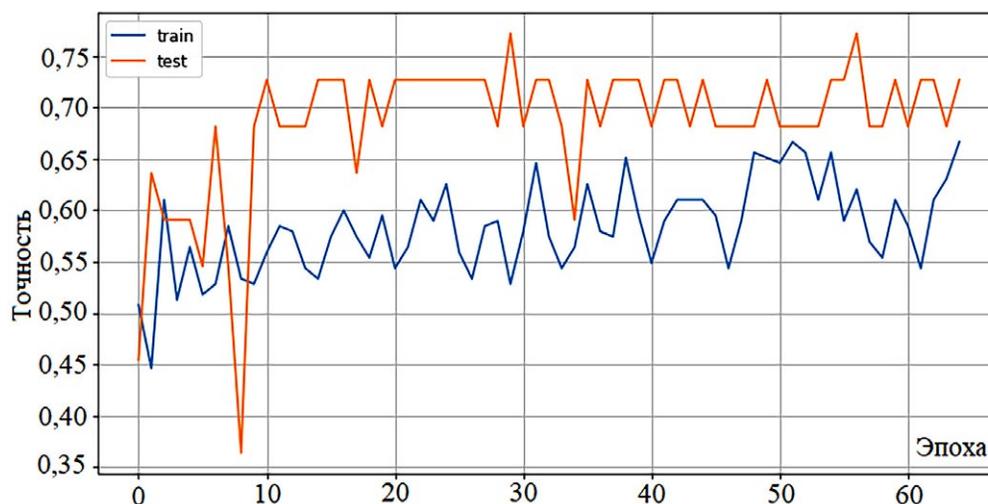


Рис. 8. График точности прогнозирования (ассурагу) в процессе обучения

Fig. 8. Graph of the forecast accuracy during training

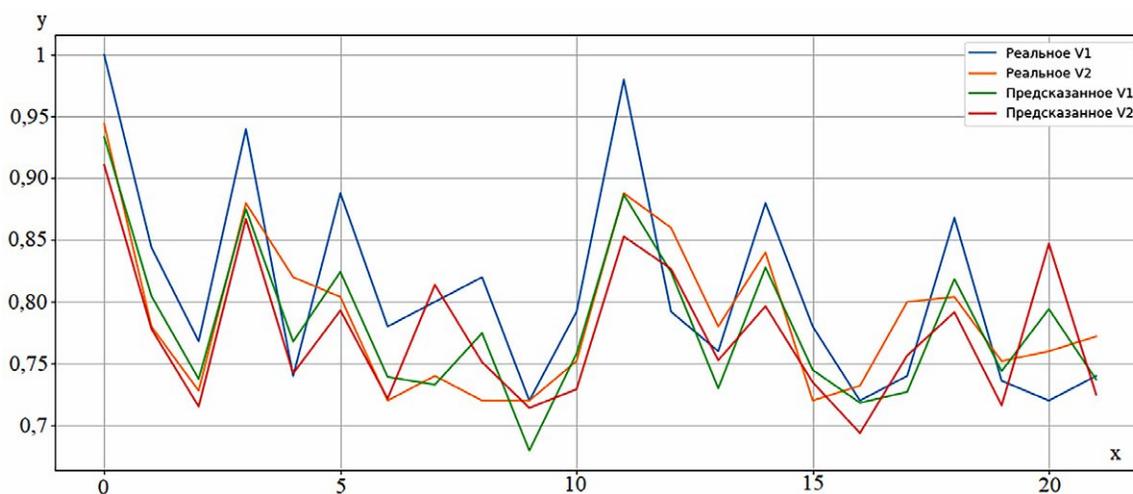


Рис. 9. Графики прогноза модели нейронной сети на тестовой

Fig. 9. Prediction graphs of the neural network model on the test sample

## ОБСУЖДЕНИЕ

В рамках данной работы производилась разработка тестовой модели электромобиля для проверки гипотезы и построения теории нейросетевого управления электроприводом для реализации электронно-дифференциальной системы. Как выяснилось в результате, данное решение имеет право быть хорошим вариантом на замену иным алгоритмам. Также, поскольку НС имеют большую гибкость и обучаемость, то на базе данного дифференциала можно также реализовать дополнительные функции помощи водителю, такие как ESP, ABS, круиз-контроль и др. [20–22].

В качестве метода отслеживания отклонения от идеальной траектории можно использовать закреплённую камеру над линией движения. Само отклонение можно будет вычислить по времени, когда проводились замеры с датчиков и при помощи алгоритмов определения расстояния, либо простым переводом пикселей в миллиметры, что существенно ускорит процесс снятия данных.

В статье была рассмотрена концепция компоновки с двумя ведущими двигателями сзади автомобиля. Однако, остается не закрытым вопрос получения модели для ведущих колёс спереди и полноприводного решения. Базово, предложенный алгоритм и код никак не меняется, необходимо лишь расширить число параметров скорости для полноприводной конфигурации.

## ЗАКЛЮЧЕНИЕ

Предложенная методика сбора данных для нейронной сети на основе специальной карты идеальных кривых поворота показала себя как рабочий инструмент для целей обучения ИНС электронного дифференциала. Также стоит отметить, что код программы и схема работы, в целом, подразумевает как расширение, так и сужение количества измеряемых параметров без значительных изменений исходного кода, что положительно влияет на универсальность решения.

Из графиков процесса обучения функции потерь и точности прогнозирования можно сделать вывод о неплохой точности прогноза даже при условии небольшого количества исходных данных для обучения, что позволило получить следующие точность прогнозирования равную 0,7273, среднеквадратичное отклонение для тренировочной выборки равное 0,064, а для тестовой выборки равное 0,065.

## РЕКОМЕНДАЦИЯ

Доктор технических наук, профессор кафедры электропривода, механотроники и электродинамики Южно-Уральского государственного университета Александр Григорьевич Возьмилов рекомендует данную статью к публикации.

**Автор заявляет, что** настоящая статья не содержит каких-либо исследований с участием людей в качестве объектов исследований.

**The author declares that** this article does not contain any studies involving human subjects.

**БИБЛИОГРАФИЧЕСКИЙ СПИСОК**

1. Khan-Ngern W., Keyoonwong W. Embedded electronic differential system on two brushless DC motor drives for electric vehicle steering control. In: 2018 International Conference on Embedded Systems and Intelligent Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES). IEEE, 2018. doi: 10.1109/ICESIT-ICICTES.2018.8442060
2. Meier T., Rinderknecht S., Fietzek R. Electric power train configurations with appropriate transmission systems // SAE Technical Paper. 2011. doi: <https://doi.org/10.4271/2011-01-0942>
3. Yıldırım M., Öksüztepe E., Tanyeri B., Kürüm H. Electronic differential system for an electric vehicle with in-wheel motor. In: 9th International Conference on Electrical and Electronics Engineering (ELECO). IEEE, 2015. P. 1048–1052. doi: 10.1109/ELECO.2015.7394567
4. Chen S., Yin G., Jin X. Study on the active steering system with direct yaw-moment control for electric vehicle with electric motored wheels. In: 35th Chinese Control Conference (CCC). IEEE, 2016. P. 8945–8950. doi: 10.1109/ChiCC.2016.7554785
5. Hu J.S., Wang Y., Fujimoto H., Hori Y. Robust yaw stability control for in-wheel motor electric vehicles // ASME Transactions On Mechatronics. 2017. Vol. 22, N. 3. P. 1360–1370. doi: 10.1109/TMECH.2017.2677998
6. Nam K., Oh S., Hori Y. Robust yaw stability control for electric vehicles based on active steering control. In: IEEE Vehicle Power and Propulsion Conference. IEEE, 2010. doi: 10.1109/VPPC.2010.5729202
7. Bose B.K. Neural network applications in power electronics and motor drives – An introduction and perspective // IEEE Transactions on Industrial Electronics. 2007. Vol. 54, N. 1. P. 14–33. doi: 10.1109/TIE.2006.888683
8. Лисов А.А., Кулганатов А.З., Панишев С.А. Акустическое обнаружение транспортных средств аварийных служб с использованием сверхточных нейронных сетей // Инновационные транспортные системы и технологии. 2023. Т. 9, № 1. С. 95–107. doi: 10.17816/transsyst20239195-107
9. Vozmilov A., Andreev L., Lisov A. Development of an algorithm for the program to recognize defects on the surface of hot-rolled metal. In: International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM). IEEE, 2022. P. 1004–1008. doi: 10.1109/ICIEAM54945.2022.9787116
10. Cirrincione M, Pucci M, Cirrincione G, Capolino GA. Sensorless control of induction machines by a new neural algorithm: The TLS EXIN neuron // IEEE Transactions on Industrial Electronics. 2007. Vol. 54, N. 1. P. 127–49. doi: 10.1109/TIE.2006.888774
11. Карандеев Д.Ю., Энгель Е.А. Прямое управление моментом асинхронного двигателя с использованием адаптивного нейроконтроллера в условиях неопределенности // Интернет-журнал «Науковедение». 2015. Т. 7, № 5(30). С. 124–131. doi: 10.15862/91TVN515
12. Zhang W., Liu Z., Chen Q. Electronic differential system based on adaptive SMC combined with QP for 4WID electric vehicles // World Electric Vehicle Journal. 2021. Vol. 12, N. 3. P. 126–132. doi: 10.3390/wevj12030126

13. Haddoun A., Benbouzid M.E., Diallo D., et al. Analysis, modeling and neural network traction control of an electric vehicle without differential gears. In: IEEE International Electric Machines & Drives Conference. IEEE, 2007. P. 854–859. doi: 10.1109/IEMDC.2007.382780
14. J Lee J.S., Ryoo Y.J., Lim Y.C., et al. A neural network model of electric differential system for electric vehicle. In: 26th Annual Conference of the IEEE Industrial Electronics Society. IECON, 2000. P. 83–88. doi: 10.1109/IECON.2000.973130
15. Rubaai A., Castro-Sitiriche M.J., Garuba M., Burge L. Implementation of artificial neural network-based tracking controller for high-performance stepper motor drives // IEEE Transactions on Industrial Electronics. 2007. Vol. 54, N. 1. P. 218–227. doi: 10.1109/TIE.2006.888785
16. Jung S., su Kim S. Hardware implementation of a real-time neural network controller with a DSP and an FPGA for nonlinear systems // IEEE Transactions on Industrial Electronics. 2007. Vol. 54, N. 1. P. 265–271. doi: 10.1109/TIE.2006.888791
17. Lin F.J., Huang P.K., Chou W.D. Recurrent-fuzzy-neural-network-controlled linear induction motor servo drive using genetic algorithms // IEEE Transactions on Industrial Electronics. 2007. Vol. 54, N. 3. P. 1449–1461. doi: 10.1109/TIE.2007.892256
18. Lin C.M, Hsu C.F. Recurrent-neural-network-based adaptive-backstepping control for induction servomotors // IEEE Transactions on industrial electronics. 2005. Vol. 52, N. 6. P. 1677–1684. doi: 10.1109/TIE.2005.858704
19. Wlas M., Krzeminski Z., Guzinski J., et al. Artificial-neural-network-based sensorless nonlinear control of induction motors // IEEE Transactions on Energy Conversion. 2005. Vol. 20, N. 3. P. 520–528. doi: 10.1109/TEC.2005.847984
20. Yousefzadeh M., Azadi S., Soltani A. Road profile estimation using neural network algorithm // Journal of mechanical science and technology. 2010. Vol. 24. P. 743–754. doi: 10.1007/s12206-010-0113-1
21. Šabanovič E., Žuraulis V., Prentkovskis O., Skrickij V. Identification of road-surface type using deep neural networks for friction coefficient estimation // Sensors. 2020. Vol. 20, N. 3. P. 612. doi: 10.3390/s20030612
22. Yi T., Xin Z., Liang Z., Xinn Z. Intelligent energy management based on driving cycle identification using fuzzy neural network. Second International Symposium on Computational Intelligence and Design. IEEE, 2009. P. 501–504. doi: 10.1109/ISCID.2009.271

## REFERENCES

1. Khan-Ngern W, Keyoonwong W. Embedded electronic differential system on two brushless DC motor drives for electric vehicle steering control. In: *2018 International Conference on Embedded Systems and Intelligent Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES)*. IEEE; 2018. doi: 10.1109/ICESIT-ICICTES.2018.8442060
2. Meier T, Rinderknecht S, Fietzek R. Electric power train configurations with appropriate transmission systems. *SAE Technical Paper*. 2011. doi: <https://doi.org/10.4271/2011-01-0942>

3. Yıldırım M, Öksüztepe E, Tanyeri B, Kürüm H. Electronic differential system for an electric vehicle with in-wheel motor. In: *9th International Conference on Electrical and Electronics Engineering (ELECO)*. IEEE; 2015;1048–1052. doi: 10.1109/ELECO.2015.7394567
4. Chen S, Yin G, Jin X. Study on the active steering system with direct yaw-moment control for electric vehicle with electric motored wheels. In: *35th Chinese Control Conference (CCC)*. IEEE; 2016;8945–8950. doi: 10.1109/ChiCC.2016.7554785
5. Hu J.S, Wang Y, Fujimoto H, Hori Y. Robust yaw stability control for in-wheel motor electric vehicles. *ASME Transactions On Mechatronics*. 2017;22(3):1360–1370. doi: 10.1109/TMECH.2017.2677998
6. Nam K, Oh S, Hori Y. Robust yaw stability control for electric vehicles based on active steering control. *IEEE Vehicle Power and Propulsion Conference*. IEEE; 2010:1–5. doi: 10.1109/VPPC.2010.5729202
7. Bose BK. Neural network applications in power electronics and motor drives – An introduction and perspective. *IEEE Transactions on Industrial Electronics*. 2007; 54(1):14–33. doi: 10.1109/TIE.2006.888683
8. Lisov AA, Kulganatov AZ, Panishev SA. Using convolutional neural networks for acoustic based emergency vehicle detection. *Modern Transportation Systems and Technologies*. 2023;9(1):95–107 (in Russ.) doi: 10.17816/transsyst20239195-107
9. Vozmilov A, Andreev L, Lisov A. Development of an algorithm for the program to recognize defects on the surface of hot-rolled metal. In: *International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*. 2022:1004–1008. doi: 10.1109/ICIEAM54945.2022.9787116
10. Cirrincione M, Pucci M, Cirrincione G, Capolino GA. Sensorless control of induction machines by a new neural algorithm: The TLS EXIN neuron. *IEEE Transactions on Industrial Electronics*. 2007;54(1):127–49. doi: 10.1109/TIE.2006.888774
11. Karandeev DJ, Engel EA. Direct torque control of induction motor using adaptive neurocontroller under conditions of uncertainty. *Online journal “Science Studies”*. 2015;5(30):124–131. doi: 10.15862/91TVN515
12. Zhang W, Liu Z, Chen Q. Electronic differential system based on adaptive SMC combined with QP for 4WID electric vehicles. *World Electric Vehicle Journal*. 2021;12(3):126–132. doi: 10.3390/wevj12030126
13. Haddoun A, Benbouzid ME, Diallo D, et al. Analysis, modeling and neural network traction control of an electric vehicle without differential gears. *IEEE International Electric Machines & Drives Conference*. IEEE; 2007:854–859. doi: 10.1109/IEMDC.2007.382780
14. J Lee JS, Ryoo YJ, Lim YC, et al. A neural network model of electric differential system for electric vehicle. In: *26th Annual Conference of the IEEE Industrial Electronics Society*. IECON IEEE; 2000:83–88. doi: 10.1109/IECON.2000.973130
15. Rubaai A, Castro-Sitiriche MJ, Garuba M, Burge L. Implementation of artificial neural network-based tracking controller for high-performance stepper motor drives. *IEEE Transactions on Industrial Electronics*. 2007;54(1):218–27. doi: 10.1109/TIE.2006.888785

16. Jung S, su Kim S. Hardware implementation of a real-time neural network controller with a DSP and an FPGA for nonlinear systems. *IEEE Transactions on Industrial Electronics*. 2007;54(1):265–71. doi: 10.1109/TIE.2006.888791
17. Lin FJ, Huang PK, Chou WD. Recurrent-fuzzy-neural-network-controlled linear induction motor servo drive using genetic algorithms. *IEEE Transactions on Industrial Electronics*. 2007;54(3):1449–1461. doi: 10.1109/TIE.2007.892256
18. Lin CM, Hsu CF. Recurrent-neural-network-based adaptive-backstepping control for induction servomotors. *IEEE Transactions on industrial electronics*. 2005;5;52(6):1677–1684. doi: 10.1109/TIE.2005.858704
19. Wlas M, Krzeminski Z, Guzinski J, et al. Artificial-neural-network-based sensorless nonlinear control of induction motors. *IEEE Transactions on Energy Conversion*. 2005;20(3):520–8. doi: 10.1109/TEC.2005.847984
20. Yousefzadeh M, Azadi S, Soltani A. Road profile estimation using neural network algorithm. *Journal of mechanical science and technology*. 2010;24:743–54. doi: 10.1007/s12206-010-0113-1
21. Šabanovič E, Žuraulis V, Prentkovskis O, Skrickij V. Identification of road-surface type using deep neural networks for friction coefficient estimation. *Sensors*. 2020;20(3):612. doi: 10.3390/s20030612
22. Yi T, Xin Z, Liang Z, Xinn Z. Intelligent energy management based on driving cycle identification using fuzzy neural network. *Second International Symposium on Computational Intelligence and Design* 2009:501–504. doi: 10.1109/ISCID.2009.271

**Сведения об авторе:**

**Лисов Андрей Анатольевич**, аспирант;  
eLibrary SPIN: 1956-3662; ORCID: 0000-0001-7282-8470;  
E-mail: lisov.andrey2013@yandex.ru

**Information about the author:**

**Andrey A. Lisov**, postgraduate student;  
eLibrary SPIN: 1956-3662; ORCID: 0000-0001-7282-8470;  
E-mail: lisov.andrey2013@yandex.ru