ЛЕКЦИЯ 15
МАШИННОЕ ОБУЧЕНИЕ В ЗАДАЧАХ КАЛИБРОВКИ. АВТОМАТИЗИРОВАННАЯ НАСТРОЙКА ПАРАМЕТРОВ И ОПТИМИЗАЦИЯ АЛГОРИТМОВ УПРАВЛЕНИЯ ТРАНСМИССИЕЙ

Цель

Сформировать у обучающихся системное представление о применении методов машинного обучения для автоматизации калибровки и оптимизации алгоритмов управления трансмиссией. Рассмотреть проблемы традиционной калибровки, методы машинного обучения (нейронные сети, обучение с подкреплением, обучение на основе демонстраций) для автоматизированной настройки параметров, а также практические примеры и перспективы развития интеллектуальных калибровочных систем.

Планируемые результаты

После изучения данной лекции обучающийся сможет:

- объяснять, почему калибровка алгоритмов управления трансмиссией является критической и ресурсоёмкой задачей;
- характеризовать ограничения традиционных подходов к калибровке;
- описывать применение искусственных нейронных сетей для автоматической калибровки параметров переключения передач;
- объяснять принципы использования обучения с подкреплением для автономной настройки карт переключения;
- характеризовать многокритериальные подходы к калибровке, учитывающие как топливную эффективность, так и комфорт водителя;
- анализировать практические примеры внедрения машинного обучения в калибровочные процессы.

Вопрос занятия. Современная автоматическая трансмиссия с 10 передачами требует калибровки более 22 000 параметров. Традиционный подход — это годы работы инженеров-калибровщиков, тысячи часов испытаний на прототипах, бесконечные компромиссы между топливной экономичностью, динамикой и комфортом. Но что, если эту работу можно поручить алгоритмам машинного обучения? Смогут ли нейронные сети и агенты с подкреплением найти оптимальные настройки быстрее и лучше человека? И главное — как сделать так, чтобы эти алгоритмы учитывали не только расход топлива, но и субъективные ощущения водителя?

1. Введение в калибровку алгоритмов управления трансмиссией

1.1. Что такое калибровка и почему она критична?

Калибровка алгоритмов управления трансмиссией — это процесс настройки многочисленных параметров, определяющих поведение автоматической трансмиссии в различных условиях эксплуатации. Эти параметры

включают карты переключения передач (shift maps), которые определяют, на какой передаче должна работать трансмиссия в зависимости от скорости, нагрузки, положения педали акселератора и других факторов, а также параметры управления гидравлическими клапанами, муфтами и другими исполнительными механизмами.

Калибровка является критическим этапом разработки автомобиля, поскольку она непосредственно определяет:

- **Топливную экономичность.** Неправильно настроенные карты переключения могут привести к тому, что двигатель будет работать в неэффективной зоне, увеличивая расход топлива.
- **Динамические характеристики.** Калибровка определяет отзывчивость автомобиля на нажатие педали акселератора, время переключения передач.
- **Комфорт вождения (drivability).** Рывки при переключении, задержки, неожиданные переключения — всё это определяется калибровкой.
- **Долговечность компонентов.** Неправильная калибровка может привести к повышенному износу муфт и других компонентов трансмиссии.
- **Выбросы вредных веществ.** Оптимизация режимов работы двигателя через калибровку трансмиссии влияет на экологические показатели.

1.2. Проблемы традиционной калибровки

Традиционная калибровка алгоритмов управления трансмиссией сталкивается с рядом серьёзных проблем, которые делают этот процесс дорогостоящим и длительным.

Экспоненциальный рост параметров. По мере увеличения числа передач в автоматических трансмиссиях количество параметров калибровки растёт экспоненциально. Типичная 10-ступенчатая трансмиссия требует калибровки более 22 000 параметров. Каждый новый параметр увеличивает размерность пространства поиска, делая ручную калибровку всё более сложной и трудоёмкой.

Высокая стоимость и длительность. Традиционная калибровка требует обширных испытаний на прототипах с участием экспертов-калибровщиков. Этот процесс дорог, длителен и подвержен вариациям из-за изменения условий окружающей среды и субъективности человеческого суждения.

Необходимость балансировки конфликтующих целей. Калибровщики должны находить глобальный оптимальный баланс между тремя конфликтующими целями для тысяч шаблонов переключения: продолжительность переключения, комфорт переключения и тепловые потери в муфте.

Сложность и нелинейность системы. Процесс переключения передач включает сложные электрогидравлические реакции, динамику включения муфт и нелинейные характеристики трения, которые сильно чувствительны к колебаниям температуры масла и старению компонентов.

Ограниченная наблюдаемость. Производственные автомобили обычно оснащены только датчиками угловой скорости, но не имеют недорогих датчиков для прямого измерения гидравлического давления или крутящего момента на выходном валу. Это создаёт «слепые» периоды во время

критических этапов, таких как фаза заполнения муфты и передача крутящего момента.

Зависимость от субъективных оценок. Качество калибровки часто оценивается субъективно — на основе ощущений водителя. Это вносит вариабельность и затрудняет воспроизводимость результатов.

Отсутствие адаптации к износу. Традиционные калибровки статичны и не учитывают изменение характеристик компонентов в процессе эксплуатации (износ муфт, изменение коэффициента трения).

Именно эти проблемы делают применение методов машинного обучения для автоматизации калибровки не просто желательным, а необходимым шагом в развитии автомобильной инженерии.

1.3. Место машинного обучения в процессе калибровки

Машинное обучение предлагает принципиально новый подход к калибровке, который может быть интегрирован на различных этапах процесса разработки:

На этапе разработки в симуляции (SiL — Software-in-the-Loop). Алгоритмы машинного обучения могут автономно настраивать параметры в виртуальной среде, значительно сокращая потребность в дорогостоящих физических испытаниях.

На этапе калибровки на стенде (HiL — Hardware-in-the-Loop). Обученные модели могут быть перенесены на реальное оборудование для финальной настройки с минимальными доработками.

В процессе эксплуатации (online adaptation). Методы онлайн-обучения позволяют адаптировать калибровку к изменяющимся условиям, стилю вождения и старению компонентов.

Для персонализации. Машинное обучение позволяет настраивать калибровку под индивидуальные предпочтения водителя.

2. Нейросетевые методы автоматической калибровки

2.1. Принцип работы нейросетевого калибратора

Искусственные нейронные сети (artificial neural networks, ANNs) предлагают мощный подход к автоматизации калибровки, основанный на способности сетей аппроксимировать сложные нелинейные зависимости между входными и выходными переменными.

Основная идея: нейронная сеть обучается устанавливать нелинейное отображение между характеристиками переключения (например, время переключения, рывки, тепловые потери) и параметрами калибровки (давление в муфте, время заполнения, токи соленоидов). После обучения сеть может предсказывать оптимальные параметры калибровки для заданных целевых характеристик, имитируя и заменяя процесс анализа и настройки, выполняемый инженерами-калибровщиками.

Процесс калибровки с использованием ANN:

1. **Сбор данных.** Строится модель автомобиля (например, на основе 9-ступенчатой автоматической трансмиссии). Путём перебора различных комбинаций параметров получается большой набор данных о характеристиках переключения.
2. **Извлечение признаков.** Из полученных данных извлекаются ключевые признаки, характеризующие качество переключения.
3. **Обучение сети.** Нейронная сеть обучается на собранных данных, устанавливая связь между характеристиками переключения и параметрами калибровки.
4. **Автоматическая калибровка.** Для заданных целевых характеристик переключения обученная сеть предсказывает оптимальные параметры калибровки.
5. **Итеративное уточнение.** При необходимости процесс может быть повторён для достижения требуемой точности.

2.2. Преимущества нейросетевого подхода

Исследования показывают, что нейросетевые калибраторы обладают рядом существенных преимуществ по сравнению с традиционными методами:

Высокая скорость сходимости. Обученная нейросетевая модель требует всего **4–5 итераций** для доведения качества переключения до уровня, сравнимого с ручной калибровкой. Это значительно быстрее традиционных методов калибровки на основе правил.

Отсутствие зависимости от высокоточных физических моделей. Нейросетевой подход не требует построения высокоточных физических моделей системы, что упрощает разработку и снижает требования к вычислительным ресурсам.

Способность к обобщению. Модель демонстрирует определённую способность к обобщению и робастность при различных открытиях дроссельной заслонки и условиях переключения передач.

Сокращение цикла разработки. Автоматизация калибровки значительно сокращает время разработки и повышает эффективность калибровочных работ.

2.3. Особенности задачи калибровки

Задача калибровки автоматической трансмиссии имеет ряд особенностей, которые делают её особенно подходящей для применения нейронных сетей:

Высокая размерность. С ростом числа передач количество параметров калибровки растёт экспоненциально, что делает ручную калибровку практически невозможной.

Сильная нелинейность. Процесс переключения передач характеризуется сложными нелинейными зависимостями, которые трудно описать аналитически.

Многокритериальность. Необходимо балансировать между продолжительностью переключения, комфортом и тепловыми потерями.

Ограниченная наблюдаемость. Отсутствие датчиков давления и крутящего момента создаёт «слепые» зоны в процессе управления.

Именно эти особенности делают нейросетевой подход, способный аппроксимировать сложные нелинейные зависимости на основе данных, особенно эффективным для задачи калибровки.

3. Калибровка на основе обучения с подкреплением

3.1. Искусственный калибратор (Artificial Calibrator)

Одним из наиболее перспективных подходов к автоматизации калибровки является использование **обучения с подкреплением (Reinforcement Learning, RL)** для создания «искусственного калибратора» — программного агента, который автономно настраивает карты переключения трансмиссии.

Принцип работы искусственного калибратора:

Вместо того чтобы программировать правила калибровки вручную, искусственный калибратор обучается методом проб и ошибок в среде симуляции. Агент (калибратор) взаимодействует с моделью трансмиссии (среда), выбирая параметры калибровки (действия) и получая обратную связь в виде расхода топлива или других показателей эффективности (вознаграждение).

Ключевые элементы:

- **Среда (Environment).** Модель трансмиссии, например, 7-ступенчатая трансмиссия с двойным сцеплением (DCT) гибридного автомобиля (MHEV). Среда может быть реализована как Software-in-the-Loop (SiL) симуляция, что позволяет проводить тысячи итераций обучения без затрат на физические испытания.
- **Агент (Agent).** Алгоритм обучения с подкреплением, который исследует пространство параметров калибровки и учится на обратной связи о расходе топлива.
- **Вознаграждение (Reward).** Функция, которая оценивает качество выбранных параметров. Обычно это расход топлива на заданном ездовом цикле. В многокритериальных подходах вознаграждение может также учитывать комфорт вождения.

3.2. Результаты применения искусственного калибратора

Применение искусственного калибратора на основе обучения с подкреплением демонстрирует впечатляющие результаты.

Случай 1: Оптимизация от базовой калибровки

В исследовании на 7-ступенчатой DCT гибридного автомобиля (MHEV) на участке WLTC протяжённостью 4,7 км искусственный калибратор, обученный с нуля, снизил расход топлива с базового уровня **0,46 л до 0,37 л** — улучшение более чем на 19%.

Случай 2: Дальнейшая оптимизация уже оптимизированной калибровки

Когда искусственный калибратор применялся к уже оптимизированной карте переключения, представляющей калибровку серийного автомобиля, он достиг дополнительного снижения расхода топлива примерно на **0,6%** для участка 4,7 км и почти на **5%** для полного цикла WLTC.

Эти результаты демонстрируют, что даже лучшие ручные калибровки могут быть улучшены с помощью методов машинного обучения. Искусственный калибратор предлагает многообещающую методологию для переноса задач калибровки в симуляцию, что даёт возможность сократить зависимость от ресурсоёмких физических испытаний и значительно ускорить разработку программного обеспечения для управления силовыми агрегатами.

3.3. Многокритериальная оптимизация с учётом комфорта вождения

Хотя снижение расхода топлива является важной целью, для реального принятия калибровки пользователями не менее важны **комфорт вождения (drivability)** и субъективные предпочтения водителя.

Проблема однокритериального подхода. Предыдущие методологии, основанные исключительно на обучении с подкреплением для минимизации расхода топлива, не учитывали такие аспекты, как комфорт водителя и его предпочтения, которые имеют первостепенное значение для реального принятия пользователями и управляемости.

Многокритериальный подход. Современные исследования предлагают многокритериальную структуру оптимизации, которая расширяет искусственный калибратор для одновременной максимизации топливной эффективности и повышения комфорта водителя. Этот метод вводит модифицированную функцию вознаграждения RL, которая штрафует нежелательное поведение при переключении, чтобы обеспечить плавность вождения.

Учёт предпочтений водителя. Новая методология также включает механизм для захвата и интеграции предпочтений водителя, переходя от чисто количественной цели, ориентированной на экономию топлива, к целостной, ориентированной на пользователя калибровке.

Экспериментальная оценка показывает, что расширенная структура успешно генерирует стратегию переключения, которая достигает выгодного компромисса между топливной эффективностью и управляемостью, что приводит к более сбалансированной и практичной калибровке. Способность интегрировать эти качественные факторы в автоматизированный процесс, управляемый данными, представляет собой значительный шаг вперёд, обещая ускорить разработку систем управления силовыми агрегатами, которые одновременно высокоэффективны и соответствуют ожиданиям водителей.

3.4. Другие применения RL в калибровке трансмиссии

Обучение с подкреплением находит применение и в других аспектах калибровки трансмиссии.

Калибровка управления муфтой. Калибровка управления заполнением и включением муфты может улучшить качество и эффективность переключения, но является трудоёмкой, специфичной для системы и часто не обладает робастностью к изменяющимся условиям эксплуатации. Предлагается замкнутый контроллер на основе RL для заполнения и включения мокрой муфты. Метод использует алгоритм **Soft Actor-Critic (SAC)**, обученный на физическом симуляторе муфты, что позволяет контроллеру балансировать быстрое заполнение с плавной передачей крутящего момента. В отличие от традиционных стратегий калибровки, структура RL адаптируется к динамике системы и снижает зависимость от ручной настройки.

Адаптация к старению трансмиссии. Предложен новый алгоритм, который адаптируется к стареющим трансмиссиям путём регулировки коэффициента дисконтирования — ключевого параметра в обучении с подкреплением, который балансирует краткосрочные и долгосрочные вознаграждения.

Оптимизация переключения передач для коммерческих электромобилей. Принят метод «офлайн-оптимизация + онлайн-применение» с использованием динамического программирования для разработки стратегии переключения передач.

4. Сравнение подходов к автоматической калибровке

4.1. Нейросетевой подход vs. Обучение с подкреплением

Характеристика	Нейросетевой подход (ANN)	Обучение с подкреплением (RL)
Принцип	Обучение с учителем на размеченных данных	Обучение через взаимодействие со средой
Требования к данным	Требует большого набора размеченных данных	Требует симулятора среды
Скорость калибровки	4–5 итераций до целевого качества	Зависит от сложности задачи, может потребовать тысяч эпизодов
Способность к обобщению	Хорошая на данных, близких к обучающим	Хорошая при правильной формулировке вознаграждения
Учёт многокритериальности	Может быть реализован через многокритериальную оптимизацию	Естественно поддерживает через функцию вознаграждения
Вычислительная сложность	Умеренная (обучение офлайн, применение онлайн)	Высокая (обучение может быть длительным)
Применимость	Хорошо для задач с известными данными	Хорошо для задач, где сложно определить оптимальное решение явно

4.2. Традиционная калибровка vs. Машинное обучение

Характеристика	Традиционная калибровка	Калибровка на основе ML
Трудоёмкость	Высокая, требует экспертов	Низкая, автоматизирована
Время	Месяцы-годы	Дни-недели
Стоимость	Высокая (прототипы, испытания)	Низкая (симуляция, вычисления)
Воспроизводимость	Низкая (зависит от человека)	Высокая (детерминированные алгоритмы)
Адаптивность	Статичная	Может адаптироваться
Учёт субъективных факторов	Основан на опыте	Может быть формализован через функцию вознаграждения
Масштабируемость	Плохая (экспоненциальный рост параметров)	Хорошая (алгоритмы хорошо масштабируются)

5. Онлайн-адаптация и персонализация

5.1. Адаптация к изменяющимся условиям

Одним из наиболее перспективных направлений является **онлайн-адаптация** калибровки в процессе эксплуатации автомобиля.

Адаптация к старению компонентов. С течением времени характеристики трансмиссии меняются: изнашиваются фрикционные поверхности муфт, изменяется вязкость масла, появляются люфты. Традиционная статическая калибровка не учитывает эти изменения. Методы онлайн-обучения с подкреплением позволяют адаптировать параметры управления к изменяющимся характеристикам системы.

Адаптация к дорожным условиям. Предложены методы онлайн-адаптивного управления переключением передач для тяжёлых электрических коммерческих автомобилей, учитывающие уклон дороги и частоту переключений. Метод «офлайн-оптимизация + онлайн-применение» позволяет снизить энергопотребление и частоту переключений.

Адаптация к стилю вождения. Методы машинного обучения могут распознавать стиль вождения и адаптировать калибровку соответствующим образом. Например, для спортивного стиля вождения карты переключения могут быть сдвинуты в сторону более высоких оборотов для обеспечения максимальной динамики.

5.2. Персонализация калибровки

Персонализация калибровки под индивидуальные предпочтения водителя является следующим шагом в развитии интеллектуальных систем управления.

Захват предпочтений водителя. Многокритериальные структуры обучения с подкреплением включают механизмы для захвата и интеграции предпочтений водителя. Это позволяет перейти от чисто количественной цели, ориентированной на экономию топлива, к целостной, ориентированной на пользователя калибровке.

Обучение на основе демонстраций (Learning from Demonstrations). Методы обучения на основе демонстраций позволяют алгоритму изучать предпочтения водителя на основе его реальных действий. Предложен модуль для вывода намерений водителя с использованием методов мягких вычислений, который затем сдвигает стандартную карту переключения для обеспечения соответствующего шаблона переключения.

Инкрементальное обучение. Возможность непрерывного обучения в процессе эксплуатации позволяет системе постоянно уточнять калибровку на основе обратной связи от водителя.

6. Интеграция с существующими процессами разработки

6.1. Совместимость с существующей инфраструктурой

Важным аспектом внедрения методов машинного обучения является их совместимость с существующими процессами разработки и инфраструктурой.

Совместимость файлов параметров. Файлы параметров, создаваемые искусственным калибратором, напрямую совместимы с реальными электронными блоками управления (ECU) автомобилей.

Валидированное поведение в SiL. Валидированное поведение в среде Software-in-the-Loop предполагает высокую переносимость изученных стратегий, что даёт возможность минимальной доводки на физических автомобилях после симуляции.

Интеграция с существующими инструментами. Методы машинного обучения могут быть интегрированы с существующими инструментами калибровки, такими как Design of Experiments (DoE) и Model-Based Calibration (MBC).

6.2. Этапы внедрения

Этап 1: Разработка в симуляции (SiL). На этом этапе искусственный калибратор обучается в среде симуляции, используя модель трансмиссии. Это позволяет проводить тысячи итераций обучения без затрат на физические испытания.

Этап 2: Валидация на HiL (Hardware-in-the-Loop). Обученные стратегии переносятся на стенд с реальным оборудованием для валидации и финальной настройки.

Этап 3: Испытания на прототипах. После успешной валидации на HiL стратегии переносятся на физические прототипы для окончательной верификации.

Этап 4: Серийное производство. После успешных испытаний калибровка загружается в серийные ECU. При наличии возможностей онлайн-обучения система может продолжать адаптироваться в процессе эксплуатации.

6.3. Вызовы интеграции

Доверие к алгоритмам. Инженеры-калибровщики должны доверять решениям, принимаемым алгоритмами машинного обучения. Это требует разработки методов объяснимого ИИ (XAI) для калибровочных систем.

Сертификация. Калибровка, созданная с использованием методов машинного обучения, должна соответствовать требованиям функциональной безопасности (ISO 26262) и кибербезопасности (ISO/SAE 21434).

Данные для обучения. Требуются большие объёмы данных для обучения моделей. Сбор и подготовка этих данных может быть трудоёмким.

7. Перспективы развития

7.1. Федеративное обучение для калибровки

Федеративное обучение позволяет обучать модели на распределённых данных без их централизации. В контексте калибровки это означает, что данные от разных автомобилей могут использоваться для улучшения моделей без передачи самих данных в облако, что повышает приватность и снижает требования к пропускной способности.

7.2. Цифровые двойники

Цифровые двойники — это виртуальные копии физических систем, которые могут использоваться для обучения и валидации алгоритмов калибровки. Цифровой двойник трансмиссии позволяет проводить обучение в условиях, максимально приближенных к реальным, без риска повреждения оборудования.

7.3. Обучение с подкреплением на основе физических моделей

Physics-Informed Reinforcement Learning — это направление, которое объединяет физические модели с методами обучения с подкреплением для повышения эффективности и безопасности обучения. Физическая модель предоставляет априорные знания о системе, что сокращает необходимое количество взаимодействий со средой.

7.4. Автоматическая генерация карт калибровки

Развитие методов машинного обучения позволит автоматически генерировать полные карты калибровки для всех возможных условий эксплуатации, значительно сокращая время разработки и обеспечивая более высокое качество калибровки.

7.5. Интеграция с автономным вождением

В полностью автономных автомобилях калибровка трансмиссии может быть интегрирована с планированием траектории для совместной оптимизации маршрута, скорости и режимов работы трансмиссии.

8. Закрепление и завершение

8.1. Мини-тест

1. Почему традиционная калибровка трансмиссии становится всё более сложной задачей?
2. Как нейронные сети используются для автоматизации калибровки?
3. Что такое искусственный калибратор и как он работает?
4. Какие преимущества даёт многокритериальный подход к калибровке на основе RL?
5. Каковы перспективы развития методов машинного обучения для калибровки?

8.2. Эталонные краткие ответы

1. **Традиционная калибровка** становится всё более сложной из-за экспоненциального роста числа параметров (более 22 000 для 10-ступенчатой трансмиссии), высокой стоимости и длительности испытаний, необходимости балансировки конфликтующих целей, сложности и нелинейности системы, а также ограниченной наблюдаемости процессов.
2. **Нейронные сети** используются для установления нелинейного отображения между характеристиками переключения и параметрами калибровки. После обучения на большом наборе данных сеть может предсказывать оптимальные параметры для заданных целевых характеристик, имитируя процесс анализа и настройки, выполняемый инженерами.
3. **Искусственный калибратор** — это программный агент на основе обучения с подкреплением, который автономно настраивает карты переключения трансмиссии. Агент взаимодействует с симуляцией трансмиссии, выбирая параметры калибровки и получая обратную связь в виде расхода топлива, и учится на этой обратной связи для оптимизации калибровки.
4. **Многокритериальный подход** позволяет одновременно оптимизировать топливную эффективность и комфорт вождения, а также учитывать предпочтения водителя. Это приводит к более сбалансированной и практичной калибровке, которая соответствует ожиданиям пользователей.
5. **Перспективы развития** включают федеративное обучение для калибровки на распределённых данных, использование цифровых двойников, физически-информированное обучение с подкреплением, автоматическую генерацию карт калибровки и интеграцию с системами автономного вождения.

8.3. Итоговые положения

- **Калибровка алгоритмов управления трансмиссией** является критической и ресурсоёмкой задачей, сложность которой растёт экспоненциально с увеличением числа передач и требований к эффективности и комфорту.
- **Традиционная калибровка** сталкивается с проблемами высокой стоимости, длительности, субъективности и ограниченной масштабируемости.
- **Искусственные нейронные сети** позволяют автоматизировать калибровку, устанавливая нелинейное отображение между характеристиками переключения и параметрами калибровки. Требуют всего 4–5 итераций для достижения качества, сравнимого с ручной калибровкой.
- **Обучение с подкреплением** позволяет создавать искусственных калибраторов, которые автономно настраивают карты переключения, обучаясь на обратной связи о расходе топлива. Демонстрируют значительное снижение расхода топлива, в том числе дополнительное улучшение уже оптимизированных калибровок.
- **Многокритериальные подходы** расширяют возможности RL-калибраторов для учёта комфорта вождения и предпочтений водителя, что критично для реального принятия пользователями.
- **Онлайн-адаптация и персонализация** позволяют адаптировать калибровку к старению компонентов, дорожным условиям и индивидуальному стилю вождения.
- **Интеграция с существующими процессами** обеспечивается совместимостью файлов параметров с реальными ECU и возможностью переноса стратегий из симуляции на физические автомобили.
- **Перспективы развития** связаны с федеративным обучением, цифровыми двойниками, физически-информированным RL и интеграцией с автономным вождением.

Задание после лекции

Выберите один из методов машинного обучения для калибровки (нейронные сети, обучение с подкреплением, многокритериальная оптимизация, онлайн-адаптация) и подготовьте аналитический обзор (2–3 страницы), в котором:

1. Опишите выбранный метод и его применение для калибровки трансмиссии.
2. Объясните математические и алгоритмические принципы, лежащие в его основе.
3. Проанализируйте преимущества и ограничения метода.
4. Приведите примеры из научных исследований или промышленности.
5. Оцените перспективы применения метода в будущих системах управления.

Контрольные вопросы

1. Что такое калибровка алгоритмов управления трансмиссией и почему она критична?
2. Каковы основные проблемы традиционной калибровки?
3. Почему с ростом числа передач сложность калибровки растёт экспоненциально?
4. Какие конфликтующие цели должен балансировать калибровщик?
5. Что такое «ограниченная наблюдаемость» в контексте калибровки трансмиссии?
6. Как нейронные сети применяются для автоматизации калибровки?
7. Какой объём данных требуется для обучения нейросетевого калибратора?
8. Сколько итераций требуется нейросетевому калибратору для достижения качества, сравнимого с ручной калибровкой?
9. Что такое искусственный калибратор (artificial calibrator)?
10. Как работает искусственный калибратор на основе обучения с подкреплением?
11. Какие результаты были достигнуты при применении искусственного калибратора к 7-ступенчатой DCT гибридного автомобиля?
12. Какой дополнительный выигрыш в топливной эффективности даёт искусственный калибратор при применении к уже оптимизированной калибровке?
13. В чём заключается многокритериальный подход к калибровке на основе RL?
14. Как учитывается комфорт вождения в многокритериальном RL-калибраторе?
15. Как учитываются предпочтения водителя в многокритериальном подходе?
16. Как Soft Actor-Critic (SAC) применяется для калибровки управления муфтой?
17. Как методы машинного обучения позволяют адаптировать калибровку к старению трансмиссии?
18. В чём отличие нейросетевого подхода к калибровке от подхода на основе RL?
19. Каковы преимущества и недостатки каждого подхода?
20. Как методы машинного обучения интегрируются с существующими процессами разработки?
21. Что такое федеративное обучение и как оно может применяться для калибровки?
22. Что такое цифровой двойник и как он используется для калибровки?
23. Что такое физически-информированное обучение с подкреплением?

24. Как персонализация калибровки может быть реализована с использованием машинного обучения?

25. Каковы основные вызовы при внедрении методов машинного обучения в калибровочные процессы?

26. Как методы машинного обучения могут быть интегрированы с системами автономного вождения?

27. Каковы перспективы развития автоматической калибровки на основе машинного обучения?

Список рекомендуемой литературы

Основная литература

1. Robert Bosch GmbH. Automotive Handbook. 11th ed. — Chichester: Wiley, 2022. — 2047 p. — ISBN 978-1-119-91190-6.

2. Li S., Zhao Y., Guo W. Automatic Calibration Strategy Based on Artificial Neural Networks for Shift Control of Automatic Transmission // Applied Sciences. — 2026. — Vol. 16, No. 9. — P. 4432. — DOI: 10.3390/app16094432. — URL: https://www.mdpi.com/2076-3417/16/9/4432[reference:60][reference:61].

3. Kengne Dzegou T. J., Schober F., Rebesberger R., Henze R. Development of an Artificial Calibrator for Shift Program Optimization to Enhance Fuel Efficiency // SAE Technical Paper. — 2025. — No. 2025-32-0082.

Дополнительная литература

4. Multi-Objective Reinforcement Learning Framework for Transmission Shift Schedule Optimization // SAE Technical Paper. — 2026. — No. 2026-01-0162.

5. Soft Actor-Critic Based Controller for Clutch Fill and Engagement // IEEE Xplore. — 2026.

6. Reinforcement Learning with Adaptive Discount Factor for Clutch Judder Suppression with Stable Learning in Two-Speed EV Transmission // TRID. — 2025.

7. Online adaptive shift control method for heavy-duty electric commercial vehicles considering road slope and shift frequency // ScienceDirect. — 2025.

8. Deep Reinforcement Learning and Fuzzy Logic-Based Adaptive Shift Control Method of Driving Robot System // IEEE Xplore. — 2026.

9. Optimization of New Energy Vehicle Transmission System based on Feedforward Neural Network // IEEE Xplore. — 2025.

10. Shift Map Calibration Method for Intelligent Transmission System // KCI. — 2026.

11. Machine Learning Based Calibration of Dual Clutch Transmissions for Optimizing the Launch Behavior of Passenger Vehicles. — TUprints, 2024.
12. Model Based Automated Calibration for Shift Control of Automatic Transmission // International Journal of Automotive Technology. — 2021.
13. ISO 26262:2018. Road Vehicles — Functional Safety. Parts 1–10. — Geneva: International Organization for Standardization, 2018.
14. ISO/SAE 21434:2021. Road Vehicles — Cybersecurity Engineering. — Geneva: International Organization for Standardization, 2021.

Электронные ресурсы

15. SAE International. SAE Technical Papers Database. — Режим доступа: https://www.sae.org/publications/technical-papers.
16. IEEE Xplore. Scientific and Technical Publications Database. — Режим доступа: https://ieeexplore.ieee.org.
17. ScienceDirect. Scientific and Technical Publications Database. — Режим доступа: https://www.sciencedirect.com.
18. SpringerLink. Electronic Collection of Scientific and Educational Literature. — Режим доступа: https://link.springer.com.
19. MDPI. Applied Sciences Journal. — Режим доступа: https://www.mdpi.com/journal/applsci.