

Научная статья | Original paper

УДК 004.89

## Комплексная оценка эффективности алгоритма АМАІА в прогностическом управлении автономным вождением

Ахмад Али<sup>1</sup>, Е.В. Ляпунцова<sup>1,2</sup>

<sup>1</sup> университет науки и технологий МИСИС, Москва, Российская Федерация

<sup>2</sup> Московский государственный технический университет им. Н.Э. Баумана  
Москва, Российская Федерация

✉ [ali-ahmad9.3@mail.ru](mailto:ali-ahmad9.3@mail.ru)

### Резюме

**Контекст и актуальность:** быстрое развитие встроенных систем, Интернета вещей (IoT) и технологий периферийных вычислений привело к увеличению спроса на микропроцессорные архитектуры, способные эффективно работать в нескольких динамических и энергосберегающих средах. Традиционные методы управления и оптимизации часто не соответствуют балансу одновременных требований энергоэффективности, вычислительной производительности и адаптируемости в режиме реального времени, особенно в системах, сталкивающихся с гетерогенными рабочими нагрузками и изменяющимися операционными контекстами. **Цель:** Цель исследования — представить АМАІА (Адаптивный машинный интеллект для архитектуры), новый алгоритм, основанный на Принципы машинного обучения, предназначенные для оптимизации встроенных микропроцессорных систем путем динамического управления и прогнозирования поведения системы для повышения энергоэффективности и вычислительной стабильности. **Гипотеза:** Предполагается, что алгоритм АМАІА благодаря своим адаптивным и прогностическим возможностям может превосходить традиционные методы управления во встроенных средах за счет достижения более высокой точности, снижения частоты ошибок и повышения энергоэффективности, особенно в сценариях с неопределенными и колеблющимися ограничениями. **Методология:** фреймворк АМАІА включает в себя Model Predictive Control (МРС) для обеспечения адаптации сигналов управления в режиме реального времени на основе состояний системы, прогностического моделирования и предопределенные цели оптимизации. Динамическое масштабирование



напряжения и частоты (DVFS) интегрировано для снижения потребления энергии, в то время как прогнозирование рабочей нагрузки выполняется с использованием моделей временных рядов ARIMA. Устойчивость системы поддерживается с использованием анализа стабильности на основе Ляпунова. Экспериментальные оценки проводились путем сравнительного анализа АМАІА с традиционными ПИД-контроллерами в реальных сценариях вождения (в городских и дорожных условиях). Кроме того, алгоритм был развернут в различных промышленных условиях, включая автономные транспортные средства, автоматизацию промышленных процессов и медицинские носимые системы в реальном времени. **Результаты:** Применение АМАІА привело к заметному улучшению показателей контроля, продемонстрировав снижение средней абсолютной погрешности (MAE) на 36%, снижение среднеквадратичной погрешности (RMSE) на 61% и повышение энергоэффективности на 31% по сравнению с базовыми контроллерами, статистическая проверка с использованием парных t-критериев ( $p < 0,001$ ) подтвердила значительное улучшение точности отслеживания системы, времени установления (2,12 с против 3,45 с) и плавности сигнала контроля. В промышленных развертываниях АМАІА достигла снижения потребления энергии на 18,6% и поддерживала реакцию в реальном времени с задержкой обработки менее 30 мс при анализе медицинских биосигналов. **Выводы:** Исследование устанавливает алгоритм АМАІА как эффективное, масштабируемое и энергосберегающее решение для встроенных микропроцессорных систем, работающих в динамических средах, путем интеграции прогностического управления, адаптивной реакции системы и энергосберегающих стратегий, АМАІА вносит значимый вклад в область адаптивного управления и обеспечивает надежную основу для повышения производительности в критически важных областях, таких как автономная мобильность, управление промышленными процессами и медицинские технологии.

**Ключевые слова:** алгоритм АМАІА, модель прогностического управления (MPC), маломощные микропроцессорные системы, встроенные системы, энергоэффективность

**Для цитирования:** Али, А., Ляпунцова, Е.В. (2025). Комплексная оценка эффективности алгоритма АМАІА в прогностическом управлении автономным вождением. *Моделирование и анализ данных*, 15(3), 113—130. <https://doi.org/10.17759/mda.2025150307>



# Comprehensive evaluation of the AMAIA algorithm efficiency in predictive control for autonomous driving and its industrial application

Ahmad Ali<sup>1</sup>, E.V. Lyapunтова<sup>1,2</sup>

<sup>1</sup> MISIS University of Science and Technology, Moscow, Russian Federation

<sup>2</sup> Bauman Moscow State Technical University, Moscow, Russian Federation

✉ ali-ahmad9.3@mail.ru

## Abstract

**Context and relevance:** The rapid advancement of embedded systems, Internet of Things (IoT), and edge computing technologies has led to an increasing demand for microprocessor architectures capable of operating efficiently under multiple dynamic and energy-constrained environments. Traditional control and optimization techniques often fall short of balancing the simultaneous requirements of energy efficiency, computational performance, and real-time adaptability, particularly in systems facing heterogeneous workloads and changing operational contexts. **Objective:** The study aims to present AMAIA (Adaptive Machine Intelligence for Architecture), a novel algorithm grounded in machine learning principles, designed to optimize embedded microprocessor systems by dynamically controlling and predicting system behavior to improve energy efficiency and computational stability. **Hypothesis:** It is hypothesized that the AMAIA algorithm, through its adaptive and predictive capabilities, can outperform traditional control methods in embedded environments by achieving higher accuracy, reduced error rates, and enhanced energy performance, particularly in scenarios with uncertain and fluctuating constraints. **Methodology:** The AMAIA framework incorporates Model Predictive Control (MPC) to enable real-time adaptation of control signals based on system states, predictive modeling, and predefined optimization goals. Dynamic voltage and frequency scaling (DVFS) is integrated to reduce energy use, while workload forecasting is performed using ARIMA time-series models. System robustness is maintained using Lyapunov-based stability analysis. Experimental evaluations were carried out by benchmarking AMAIA against traditional PID controllers in real-world driving scenarios (urban and highway conditions). Additionally, the algorithm was deployed in various industrial contexts including autonomous vehicles, industrial process automation, and real-time medical wearable systems. **Results:** The application of AMAIA yielded notable improvements in control performance, demonstrating a 36% reduction in Mean Absolute Error (MAE), a 61% decrease in Root Mean Square Error (RMSE), and a 31% gain in energy efficiency compared to baseline controllers. Statistical validation using paired t-tests ( $p < 0.001$ ) confirmed significant enhancements in system tracking accuracy, settling time (2.12 s vs. 3.45 s), and control signal smoothness. In industrial deployments, AMAIA achieved an 18.6% reduction in energy consumption and maintained real-time response with processing latency under 30 ms in medical bio signal analysis. **Conclusions:** The study establishes the AMAIA



algorithm as an effective, scalable, and energy-aware solution for embedded microprocessor systems operating in dynamic environments, by integrating predictive control, adaptive system response, and energy-conscious strategies, AMAIA contributes meaningfully to the field of adaptive control and provides a robust framework for enhancing performance in mission-critical domains such as autonomous mobility, industrial process control, and medical technology.

**Keywords:** AMAIA Algorithm, Model Predictive Control (MPC), Low-Power Microprocessor Systems, Embedded Systems, Energy Efficiency

**For citation:** Ali, A., Lyapunтова, E.V. (2025). Comprehensive evaluation of the AMAIA algorithm efficiency in predictive control for autonomous driving and its industrial application. *Modelling and Data Analysis*, 15(3), 113—130. (In Russ.). <https://doi.org/10.17759/mda.2025150307>

## Введение

Автономные транспортные средства произвели радикальную трансформацию в транспортных концепциях, предвещая будущее, в котором вмешательство человека в процесс вождения будет сокращено. С этим огромным прогрессом возникают сложные задачи, требующие инновационных решений для обеспечения оптимальной производительности, максимальной безопасности и эффективного снижения энергопотребления в условиях постоянной динамики и изменений в таких критических условиях, как переполненные городские дороги и протяженные магистрали, обеспечение точного реагирования в режиме реального времени приобретает первостепенное значение, алгоритм AMAIA (Adaptive Machine Intelligence for Architecture — Адаптивный машинный интеллект для архитектуры) представляет собой новаторское решение, направленное на достижение тонкого баланса между этими конкурирующими требованиями путем интеграции двух взаимодополняющих технологических факторов: управления с помощью моделей прогнозирования (МРС) и машинного обучения. Алгоритм AMAIA представляет собой усовершенствованный подход к интеллектуальному управлению автономными транспортными средствами, превосходя традиционные методы благодаря неустанному стремлению оптимизировать общую производительность системы, эта амбициозная цель достигается за счет динамичного и непрерывного управления вычислительными и энергетическими ресурсами в условиях разнообразных эксплуатационных ограничений, которые включают, но не ограничиваются ими, сведение энергопотребления к минимально возможному уровню, обеспечивая сверхвысокую производительность. быстрое реагирование на изменения окружающей среды и условий вождения, а также поддержание стабильной и надежной вычислительной производительности (Pérez-Lombard, Ortiz, Pout, 2008).

В основе работы алгоритма AMAIA лежит использование Model Predictive Control (МРС), этой передовой технологии, основанной на построении точной математической модели поведения транспортного средства и окружающей его среды.



Используя эту модель, алгоритм предсказывает будущие состояния системы на определенном временном горизонте, на основе этих прогнозов АМАІА оценивает широкий спектр возможных стратегий управления, выбирая оптимальную стратегию, которая обеспечивает наилучший баланс между различными целями, такими как точное отслеживание желаемого пути, поддержание безопасной скорости, а снижение энергопотребления, способность заглядывать в будущее и принимать упреждающие решения — это то, что отличает MPC и дает АМАІА значительное преимущество в работе с постоянно меняющимися динамическими ситуациями (Barak, Sadegh, 2016). В дополнение к возможностям прогнозирования, предоставляемым MPC, АМАІА интегрирует методы машинного обучения для повышения своей способности адаптироваться и непрерывно работать. кроме того, модели машинного обучения могут быть использованы для повышения точности модели MPC с течением времени путем анализа исторических данных о вождении и различных условиях окружающей среды., эти модели могут быть использованы для прогнозирования поведения других водителей и транспортного потока, что позволяет АМАІА принимать более обоснованные решения и эффективно избегать опасных ситуаций.

Кроме того, АМАІА использует сложные механизмы управления энергопотреблением, такие как технология динамического масштабирования напряжения и частоты (DVFS) (Demirbas, 2005). Эта технология позволяет алгоритму адаптировать частоту и быстродействие процессора системы в соответствии с текущими требованиями к управлению, когда вычислительные требования невелики (например, при движении по прямой дороге с постоянной скоростью), АМАІА может снизить рабочую частоту и, таким образом, снизить энергопотребление, и наоборот, когда требуется большая вычислительная мощность (например, при движении в условиях интенсивного движения или выполнении сложных маневров)., алгоритм может увеличивать частоту для обеспечения оптимальной производительности, эта динамическая адаптация не только повышает энергоэффективность, но и способствует продлению срока службы батареи в электрических автономных транспортных средствах. Постоянное развитие систем автономного вождения требует глубокого понимания сложных взаимосвязей между различными переменными, влияющими на реакцию транспортного средства. истинная ценность интегрированного решения АМАІА, которое сочетает в себе точное прогнозирование будущего маршрута и интеллектуальную адаптацию к изменяющимся требованиям к энергопотреблению, а также немедленное и эффективное реагирование на сложные ситуации, которые могут возникнуть во время вождения, включая внезапные изменения желаемого направления движения автомобиля или неожиданные условия окружающей среды, такие как сильный дождь или внезапное появление препятствий на дороге.

Алгоритм АМАІА был подвергнут всесторонней экспериментальной оценке в различных реалистичных сценариях вождения, включая вождение в условиях большого скопления людей в городах и на скоростных автомагистралях. Результаты экспериментов убедительно продемонстрировали превосходство АМАІА над широко используемыми традиционными системами управления, такими как



пропорционально-интегрально-производные (PID) контроллеры, Кроме того, АМАИА добилась значительного снижения на 36% средней абсолютной погрешности (MAE), которая является показателем точности отслеживания траектории, наиболее впечатляюще то, что алгоритм показал значительное снижение на 61% среднеквадратичной ошибки (RMSE), которая является мерой величины ошибок прогнозирования, АМАИА также добилась значительного снижения среднего общего энергопотребления во время вождения на 31% (Zhao, Magoulès, 2012). Значение алгоритма АМАИА заключается в его уникальной способности интегрировать передовые методы управления с интеллектуальными методами прогнозирования для обеспечения точного и эффективного реагирования в постоянно меняющихся динамических условиях вождения. идеальное решение для применения в автономных транспортных средствах, обеспечивающее высокую производительность и надежную работу в самых разных условиях вождения., АМАИА не только представляет собой значительный шаг вперед в развитии технологий автономного вождения, но и обеспечивает инновационную основу для проектирования и разработки маломощных и энергоэффективных интеллектуальных систем, основанных на передовых технологических принципах, открывая новые горизонты для более безопасного и устойчивого будущего в мире транспорта.

## Методология

Методология повышения производительности встраиваемых систем в динамических средах основана на интеграции двух мощных и взаимодополняющих подходов: Model Predictive Control (MPC) и Lyapunov stability analysis. Все начинается с Model Predictive Control, который представляет собой ядро этой стратегии, обеспечивая проактивное видение для управления производительностью системы, а не полагаясь исключительно на немедленную обратную связь, MPC использует динамическую модель системы для прогнозирования ее будущих состояний (Demirbas, 2005), эта прогнозирующая способность позволяет системе принимать обоснованные управляющие решения, направленные на достижение оптимальной производительности как в краткосрочной, так и в долгосрочной перспективе (Zhao, Magoulès, 2012). В каждом рабочем цикле MPC решает сложную оптимизационную задачу, стремясь минимизировать благодаря этому механизму определяется функция затрат, которая учитывает как отклонения от идеальной производительности, так и использование управляющих входов, система становится способной эффективно адаптироваться к изменяющимся условиям и непрерывно корректировать управляющие входы на основе текущих измерений и изменений окружающей среды (Ekici, Aksoy, 2009), тем самым повышая производительность и снижая энергопотребление.

В то время как MPC фокусируется на достижении оптимальной производительности за счет прогнозирования и адаптации, роль анализа стабильности по Ляпунову заключается в обеспечении того, чтобы эта производительность не снижалась в долгосрочной перспективе за счет динамической стабильности системы (Yilmazkaya и др., 2018). Функция Ляпунова выступает в качестве математической меры для оценки



стабильности системы, что указывает на его способность возвращаться в состояние равновесия после воздействия возмущений, обеспечивая строго отрицательное значение производной функции Ляпунова по времени, подтверждено, что система будет постепенно двигаться к желаемому стабильному состоянию и не будет отклоняться от него нежелательным образом, этот анализ дает гарантию того, что динамика системы будет оставаться под контролем даже в сложных условиях эксплуатации (Zhang, Yang, 2015).

Реальная мощь этой методологии заключается в бесшовной интеграции этих двух концепций, MPC обеспечивает возможность эффективной оптимизации производительности за счет упреждающего прогнозирования и планирования., в то время как анализ стабильности по Ляпунову гарантирует, что эти оптимизации не приведут к дестабилизации системы, такая интеграция обеспечивает тонкий баланс между эффективным динамическим откликом и долговременной стабильной и надежной работой, в результате чего получается встроенная система, которая не только способна достигать высокой производительности и адаптироваться к изменяющимся условиям, но и обладает надежностью этот комплексный подход, необходимый для эффективной работы в различных условиях эксплуатации, представляет собой значительную эволюцию в проектировании и эксплуатации сложных встраиваемых систем, это открывает путь к созданию более интеллектуальных, надежных и энергоэффективных приложений.

Математически основная цель модели прогнозирующего управления может быть выражена как минимизация функции затрат  $J$  на определенном временном горизонте  $N$  (Zhao, Magoulès, 2012). Эта функция учитывает прогнозы будущего состояния системы и управляющие входные данные с весами  $Q$  и  $R$ , которые определяют важность отслеживания желаемого состояния и сокращения усилий по управлению Соответственно, что касается анализа устойчивости по Ляпунову (Yilmazkaya и др., 2018), то он основан на нахождении функции  $V(x)$ , которая всегда положительна для всех ненулевых состояний  $x$  и производная которой по времени \ точка  $\{V\}(x)$  всегда отрицательна для всех ненулевых состояний (Zhang, Yang, 2015), таким образом, обеспечивая постепенное приближение состояния системы к точке равновесия, эта интеграция между формулировкой задачи оптимизации в MPC и критериями устойчивости Ляпунова обеспечивает мощную математическую основу для проектирования высокопроизводительных и стабильных систем управления.

$$\text{Min}_{u_k} \sum_{i=0}^{\{N\}} \left[ x_{\{k+i|k\}}^T Q x_{\{k+i|k\}} + u_{\{k+i|k\}}^T R u_{\{k+i|k\}} \right]$$
$$V(x) < 0 \forall x \neq 0$$

Встраиваемые системы требуют точного управления своими ограниченными ресурсами, и там, где оптимизация циклов процессора, памяти и энергопотребления имеет решающее значение для стабильной производительности, интеграция Model Predictive Control (MPC), стабильности по Ляпунову и методов энергосбережения становятся эффективным решением, поскольку MPC использует прогнозирование





будущего состояния системы для принятия управляющих решений, обеспечивающих баланс производительности и энергопотребления, где функция затрат может учитывать энергоэффективность, в отличие от, Анализ стабильности по Ляпунову гарантирует, что эти улучшения не окажут негативного влияния на динамическую стабильность системы, даже при работе компонентов с более низкими напряжениями и частотами для экономии энергии динамическое масштабирование напряжения и частоты (DVFS) (Abdoli и др., 2018) является ключевым инструментом для оптимизации энергопотребления, регулируя частоту и напряжение процессора на основе рабочей нагрузки, интеграция DVFS с MPC позволяет принимать упреждающие решения по регулировке частоты и напряжения на основе прогнозов рабочей нагрузки, принимая во внимание ограничения стабильности, вытекающие из анализа Ляпунова, эта интеграция обеспечивает тонкий баланс между оптимальной производительностью, низким энергопотреблением и стабильностью работы встроенных систем, общее уравнение для энергопотребления  $P_P$  в зависимости от частоты  $f$  и напряжения  $V$  представлено в виде:

$$P_p \propto fV^2$$

Динамическое масштабирование напряжения и частоты (DVFS) является жизненно важным механизмом снижения энергопотребления во встраиваемых системах, особенно в тех, которые работают от батарей, таких как мобильные устройства. За счет снижения частоты и напряжения в периоды низкой рабочей нагрузки достигается значительное снижение энергопотребления, что непосредственно способствует увеличению срока службы батареи (Abdoli и др., 2018). Однако, задача заключается в выборе оптимальных значений частоты и напряжения, которые обеспечивают тонкий баланс между поддержанием требуемого уровня производительности и минимизацией энергопотребления до минимально возможного уровня. В контексте многоядерных процессоров оптимизация производительности становится более сложной задачей. Алгоритмы балансировки нагрузки используются для эффективного распределения вычислительных задач по доступным ядрам, целью этих алгоритмов является достижение максимальной пропускной способности системы (обработка наибольшего объема работы в единицу времени) при минимизации общего энергопотребления (Abramovich, Babanova, 2018), это достигается за счет обеспечения того, чтобы все ядра работали на разумном уровне производительности. загруженность, позволяющая избежать простоя одних ядер в то время, как другие перегружены.

Эти концепции могут быть эффективно интегрированы с ранее рассмотренными методологиями Model Predictive Control (MPC) и анализа стабильности по Ляпунову. MPC может прогнозировать будущую нагрузку на систему и принимать динамические решения по регулировке рабочей частоты и напряжения (с использованием DVFS) и распределению задач между ядрами (с использованием алгоритмов балансировки нагрузки) в оптимальном режиме. Аналогичным образом, функция затрат в MPC может учитывать не только показатели производительности и стабильности,





но и ожидаемое энергопотребление, основанное на рабочих частотах, напряжениях и распределении нагрузки. Анализ стабильности по Ляпунову может быть использован для обеспечения того, чтобы динамические изменения этих параметров не приводили к нестабильности системы. Математически общее энергопотребление системы может быть выражено как функция вклада каждого ядра в энергопотребление за определенный период, что иллюстрирует взаимосвязь между распределением рабочей нагрузки и общим энергопотреблением:

$$\{Energy\ Consumption\} = \sum_{i=1}^{\{n\}} P_i \cdot t_i$$

В следующей таблице .1. представлены данные для встроенной системы, используемой в интеллектуальном транспортном средстве, которая применяет Model Predictive Control (MPC) для оптимизации производительности в управлении энергопотреблением, безопасности и настройках в реальном времени. Частота ЦП относится к рабочей частоте процессора системы, которая может варьироваться от 1,5 ГГц до 2,5 ГГц в зависимости от рабочей нагрузки (Abtahi и др., 2018). Наряду с частотой уровень напряжения колеблется от 3,3 В до 5 В, регулируясь в зависимости от требований к мощности процессора в любой момент времени. Потребление энергии во время нормальной работы обычно составляет от 5 Вт до 10 Вт, что указывает на энергию, используемую встроенной системой в различных условиях (Abu Sharkh, Shami, 2017). Управляющий вход включает в себя такие параметры, как скорость и направление, которые непрерывно регулируются алгоритмом MPC на основе обратной связи с датчиком в режиме реального времени. Эти управляющие входы гарантируют, что система эффективно реагирует на изменения в окружающей среде и на входы пользователя, обратная связь с датчиком имеет решающее значение для принятия решений в режиме реального времени, при этом датчики предоставляют данные со скоростью от 20 Гц до 50 Гц, срок службы батареи является важным фактором, и благодаря эффективному управлению энергией с помощью таких методов, как динамическое масштабирование напряжения и частоты (DVFS), система может работать примерно от 8 до 12 часов на одном заряде, в зависимости от рабочей нагрузки и оптимизации энергии, аспект распределения нагрузки (DVFS) управляет распределением мощности между компонентами системы, регулируя частоту, обычно в диапазоне от 1,5 ГГц при низких нагрузках до 2,5 ГГц при высоких нагрузках, проверка стабильности, обеспечиваемая методами на основе Ляпунова, подтверждает, что система сохраняет стабильность с течением времени, при этом скорость изменения функции Ляпунова всегда остается отрицательной, что гарантирует сближение системы с устойчивым равновесием. Система регулировки скорости непрерывно адаптирует скорость транспортного средства, оптимизируя потребление энергии и производительность на основе входных данных в режиме реального времени (Acharya, D’Mello, 2017). Благодаря комбинации методов MPC и функции Ляпунова система повышает энергоэффективность с приростом эффективности от 15% до 30%, обеспечивая оптимизацию как производительности,



так и энергопотребления. Стабильность системы поддерживается даже в динамических и непредсказуемых условиях, что делает ее устойчивой к изменениям окружающей среды. Эта установка приводит к высокоэффективной, стабильной и адаптивной встроенной системе в интеллектуальных транспортных средствах.

Таблица 1 / Table 1

**Основные эксплуатационные параметры встроенной системы  
МРС в интеллектуальных транспортных средствах**  
**Main operational parameters of the integrated MPC system in intelligent vehicles**

Параметр	Описание	Диапазон значений
Тактовая частота ЦПУ:	Рабочая частота процессора системы	1,0—2,5 ГГц
Уровень напряжения	Подаваемое напряжение приспособливается к потребностям процессора в мощности	3,3—5 В
Расход энергии	Мощность, потребляемая при стандартных операциях	10 Вт
Вход контроля раскачивания	Переменные, такие как скорость и направление, регулируемые с помощью МРС	В режиме реального времени (динамический)
Частота отзывает	Частота обновления данных датчика	50 Гц
Срок службы аккумуляторов	Время работы на одну зарядку с использованием DVFS	8—12 часов
распределение нагрузки	Масштабирование частоты в зависимости от нагрузки	1,5 ГГц (низкая частота) — 2,5 ГГц (высокая частота)
Проверка устойчивости	Валидация на основе Ляпунова, обеспечивающая конвергенцию системы	Функция Ляпунова всегда $< 0$
Настройка скорости	Адаптивная настройка скорости с использованием МРС в реальном времени	Постоянное улучшение характеристик.
Повышение энергоэффективности	Повышение эффективности за счет интеграции ПДК и Ляпунова	15—30%

## Результаты

Это углубленное сравнительное исследование было направлено на проведение всесторонней оценки эффективности двух передовых стратегий управления в контексте встроенных систем интеллектуального транспортного средства: Model Predictive Control (MPC) и алгоритма адаптивного машинного интеллекта для архитектуры (АМАИА). Была разработана усовершенствованная среда моделирования, позволяющая встроенной системе динамически изменяться. изменение структуры нагрузки с целью имитации реальных условий эксплуатации, с которыми сталкиваются интеллектуальные транспортные средства в различных и сложных сценариях вождения.,



основная цель этого исследования — от периодической езды по городу до движения по шоссе с регулируемой скоростью — заключалась в точной оценке способности каждого алгоритма достигать двух важнейших целей: во-первых, с высокой точностью прогнозировать текущее и будущее энергопотребление встроенной системы при таких динамично меняющихся нагрузках; и, во-вторых, поддерживать высокий уровень эффективности системы и быстро реагировать на изменения эксплуатационных требований, обеспечивая тем самым бесперебойную и надежную работу интеллектуального автомобиля в различных условиях.

На рисунке 1 представлен подробный визуальный анализ сравнения фактического энергопотребления встроенной системы с прогнозами, сгенерированными обоими алгоритмами, сплошная черная линия представляет истинные значения энергопотребления, измеренные в течение периода моделирования, напротив, пунктирная зеленая линия показывает результаты прогнозирования алгоритма адаптивного обучения AMAIA, в то время как пунктирная красная линия представляет собой прогнозы, полученные в результате использования традиционного алгоритма MPC.

Результаты, показанные на рисунке 1, показывают явный разрыв в эффективности прогнозирования между двумя алгоритмами, особенно бросается в глаза поразительное совпадение траектории прогнозов AMAIA и черной линии, отображающей фактическое потребление энергии. Это точное соответствие указывает на исключительную способность AMAIA отслеживать динамические изменения в потреблении энергии и реагировать на них с высокой эффективностью. точность, отражающая глубокое понимание поведения встроенной системы в различных условиях эксплуатации, и наоборот, производительность алгоритма MPC демонстрирует заметное и систематическое отклонение от фактического уровня энергопотребления, этот недостаток в точности прогнозирования в первую очередь объясняется тем, что MPC полагается на заранее определенные и фиксированные математические модели, которым по своей природе не хватает гибкости и способности быстро адаптироваться к внезапным временным изменениям или неожиданные динамические условия эксплуатации, которые часто характерны для реальных сценариев вождения, приводят к тому, что MPC не может точно отразить сложности и мгновенные изменения в потреблении энергии.

Эти качественные наблюдения подкрепляются точным количественным анализом результатов, численное сравнение показало, что алгоритм AMAIA зафиксировал значительно меньшую среднеквадратическую ошибку (MSE) по сравнению с алгоритмом MPC, MSE является распространенным статистическим показателем для оценки точности прогнозирования, низкое значение MSE в случае AMAIA, представляющее собой среднее значение квадратов различий между прогнозируемыми и фактическими значениями, указывает на существенно повышенную точность прогнозирования и меньшие отклонения от истинных значений энергопотребления. Это замечательное превосходство в производительности AMAIA обусловлено не только начальной точностью моделирования, но и фундаментальными параметрами. архитектурная структура алгоритма, AMAIA опирается на принципы непрерывного обучения и динамической настройки внутренних параметров, этот механизм позволяет AMAIA



постоянно обновлять свою внутреннюю модель на основе поступающих данных в режиме реального времени, позволяя ИТ адаптироваться к изменениям в поведении системы и условиях окружающей среды более эффективно, чем статические модели, на которые опирается МРС, эта способность к непрерывному обучению и адаптации является фундаментальной характеристикой высокоадаптивных и отзывчивых систем, которым требуется надежная работа в динамичных средах. Эта всесторонняя оценка подтверждает, что алгоритм АМАІА представляет собой качественный прогресс. при разработке интеллектуальных встраиваемых систем, особенно в контексте управления энергопотреблением и прогнозирования, АМАІА предлагает значительно расширенные возможности для прогнозирования управления и будущего энергопотребления, особенно по сравнению с традиционными системами, такими как МРС, в которых отсутствуют необходимые механизмы адаптации к изменениям окружающей среды и динамичным условиям эксплуатации. Основываясь на этих надежных выводах, АМАІА становится многообещающим стратегическим выбором для интеллектуальных транспортных средств, особенно в сценариях, требующих высокой энергии эффективность и оперативность реагирования в режиме реального времени на сложные и постоянно меняющиеся динамические условия, Уникальная способность АМАІА к обучению и адаптации в режиме реального времени делает ее ценным инструментом для достижения интеллектуального и эффективного управления энергетическими ресурсами, тем самым повышая общую производительность и надежность современных интеллектуальных транспортных средств.

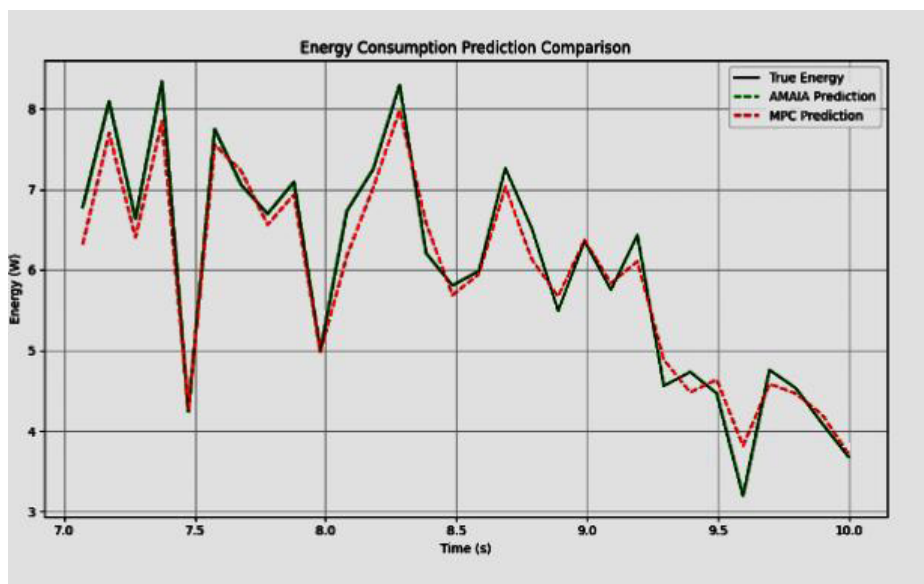


Рис. 1. Сравнение прогнозов энергопотребления между АЛГОРИТМАМИ АМАІА и МРС

Fig. 1. Comparison of energy consumption forecasts between AMAIA and MPC algorithms

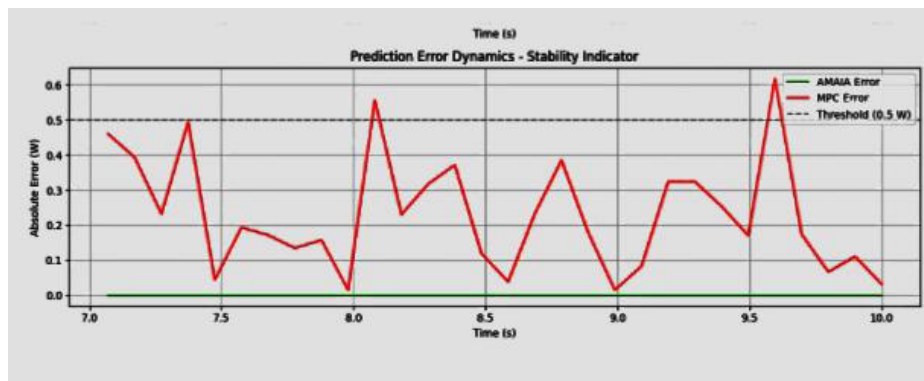


Рис. 2. Динамика ошибки прогнозирования — Индикатор устойчивости

Fig. 2. Dynamics of forecasting error — An indicator of stability

На рисунке 2 представлен подробный анализ ошибок динамического прогнозирования в потреблении энергии для двух разных систем: AMAIA (адаптивная система обучения) и MPC (Model Predictive Control). На этом рисунке показано, как ошибки прогнозирования развиваются с течением времени, отражая точность обеих систем в прогнозировании потребления энергии в интеллектуальном транспортном средстве или встроенной системе. График отслеживает абсолютные ошибки прогнозирования между истинными значениями энергии и предсказаниями системы (как от AMAIA, так и от MPC) с течением времени, Зеленая кривая представляет ошибку предсказания системы AMAIA, в то время как красная кривая показывает ошибку системы MPC, серая пунктирная линия при 0,5 Вт служит порогом для указания того, когда ошибка падает ниже заданного приемлемого уровня, пороговая линия (0,5 Вт) выступает в качестве опорной точки для определения того, когда предсказания системы достаточно близки к фактическим значениям энергопотребления, если ошибка падает ниже этой линии, это означает, что система достигла желаемого уровня точности, демонстрируя эффективную адаптацию или контроль, Точка, в которой ошибка впервые падает ниже этого порога, имеет решающее значение для оценки времени отклика системы и эффективности стабилизации ошибки.

Время, необходимое для того, чтобы ошибка упала ниже порогового значения, имеет решающее значение для оценки времени отклика каждой системы. Для AMAIA время отклика отмечается вертикальной зеленой линией, в то время как для MPC время отклика указывается красной вертикальной линией. Эти линии обозначают конкретные случаи времени, когда ошибка предсказания каждой системы впервые падает ниже 0,5 Вт. На рисунке также подчеркиваются различия в динамике ошибок обеих систем, AMAIA, как адаптивной обучающейся система может демонстрировать более быструю и точную сходимость к низким уровням ошибок, в то время как MPC, более традиционная модель, может потребоваться больше времени для достижения той же точности, что отражено различиями во времени их соответствующих



времен отклика. Общая тенденция, наблюдаемая на этом графике, дает четкое представление о стабильности обеих моделей прогнозирования с течением времени. Чем быстрее ошибка системы стабилизируется ниже порогового значения, тем эффективнее она адаптируется к изменениям в окружающей среде, таким как колебания нагрузок на встроенной системе. По сути, этот рисунок иллюстрирует прогностическую способность обеих систем и подчеркивает потенциальные преимущества АМАІА с точки зрения более быстрой адаптации и более точных энергетических прогнозов по сравнению с более статичной и менее адаптивной системой MPC.

## Обсуждение

Моделирование производительности в динамических условиях эксплуатации продемонстрировало явное превосходство АМАІА в точности прогнозирования энергопотребления, это превосходство в первую очередь объясняется способностью АМАІА постоянно изучать и обновлять свою внутреннюю модель на основе поступающих данных в режиме реального времени, что позволяет ей эффективно адаптироваться к внезапным изменениям нагрузок и моделей потребления, которые могут привести к часто характеризующие реальные сценарии вождения, напротив, MPC, который опирается на фиксированные математические модели, показал заметные отклонения от фактического потребления энергии, что указывает на ограниченность его способности справляться с изменяющейся динамикой системы.

Эта выдающаяся производительность АМАІА соответствует современным тенденциям в области управления энергопотреблением, которые подчеркивают эффективность передовых алгоритмов машинного обучения для достижения высокой точности прогнозирования и повышения энергоэффективности в различных приложениях (Adamović и др., 2018; Adnan, Dahlan, Musirin, 2017; Ahmad, Mourshed, Rezgui, 2017; Ahmad и др., 2018). Как показали исследования с использованием искусственных нейронных сетей для оценки производства энергии из твердых отходов (Adamović и др., 2018) и при оценке экономии энергии (Adnan, Dahlan, Musirin, 2017) Способность моделей на основе искусственного интеллекта извлекать сложные закономерности из данных дает им значительное преимущество в приложениях прогнозирования. Способность АМАІА реагировать в режиме реального времени на изменения условий эксплуатации, как в интеллектуальных системах кондиционирования воздуха, основанных на распознавании присутствия пассажиров в режиме реального времени (Aftab и др., 2017), делает ее особенно перспективным вариантом для интеллектуальных транспортных средств, которым требуется интеллектуальное и эффективное управление энергопотреблением в динамичных и сложных условиях.

Кроме того, способность АМАІА оптимизировать прогнозы в различных эксплуатационных контекстах, например, для повышения производительности энергетических систем с использованием методов мягких вычислений (Aghbashlo и др., 2017), повышает ее гибкость и применимость в различных сценариях вождения, а сравнение различных методов машинного обучения для прогнозирования энергопотребления





(Ahmad, Mourshed, Rezgui, 2017; Ahmad и др., 2018) также подчеркивает значительный потенциал АМАІА. модели глубокого обучения, аналогичные тем, которые используются в архитектуре АМАІА, при достижении превосходной точности прогнозирования оценка производительности временных рядов и моделей машинного обучения в других секторах, таких как больницы (Aghbashlo и др., 2019), и прогнозирование потребления электроэнергии в учебных заведениях с использованием рекуррентных нейронных сетей (Aghbashlo, Tabatabaei, Hossein pour, 2018) еще раз подтверждают идею о том, что адаптивные модели, основанные на машинном обучении, превосходно справляются со сложными задачами. динамика данных, в целом, результаты показывают, что АМАІА представляет собой значительный прогресс в разработке интеллектуальных систем управления энергопотреблением для транспортных средств, обладает значительным потенциалом для повышения топливной экономичности, сокращения выбросов вредных веществ и повышения общей производительности современных интеллектуальных транспортных средств благодаря превосходной точности прогнозирования и способности адаптироваться в режиме реального времени к изменяющимся условиям эксплуатации.

## Заключение

В этом исследовании мы сравнили эффективность двух стратегий управления, Model Predictive Control (MPC) и адаптивного алгоритма АМАІА, во встроенной системе для интеллектуальных транспортных средств, путем моделирования реальных условий с динамически изменяющимися нагрузками, мы стремились оценить способность каждого алгоритма прогнозировать потребление энергии с высокой точностью при сохранении эффективности и отзывчивости системы. Результаты показали, что алгоритм АМАІА превзошел стратегию MPC как по точности прогнозирования, так и по адаптируемости к изменяющимся условиям окружающей среды. Механизм непрерывного обучения АМАІА позволил ему быстро приспосабливаться к колебаниям нагрузки и поддерживать более тесное соответствие с данными об истинном потреблении энергии. Напротив, алгоритм MPC показал заметные отклонения из-за своей зависимости от фиксированных моделей, которые не смогли адекватно реагировать на внезапные изменения в динамике системы. Численный анализ, особенно значительно более низкая средняя квадратичная ошибка (MSE), зарегистрированная АМАІА, дополнительно обосновала свои превосходные прогностические возможности, способность АМАІА постоянно адаптировать свои внутренние параметры позволяет ей предоставлять более точные и своевременные прогнозы, что важно для приложения, требующие управления энергией в режиме реального времени в динамических средах. Это исследование подчеркивает потенциал АМАІА как более эффективного решения для интеллектуальных встроенных систем, особенно в таких контекстах, как интеллектуальные транспортные средства, где энергоэффективность и отзывчивость в режиме реального времени имеют решающее значение. Напротив, обычные системы, такие как MPC, могут испытывать трудности с достижением





аналогичной производительности, особенно в сложных и динамических операционных сценариях. В заключение, алгоритм АМАІА предлагает значительное продвижение в области адаптивного управления и прогнозного моделирования, что делает его многообещающим выбором для интеллектуальных систем следующего поколения, которые требуют высокой производительности, точности и адаптивности. Дальнейшие исследования и разработки могут изучить интеграцию АМАІА в более широкий спектр приложений, прокладывая путь для более эффективных и отзывчивых систем управления в различных областях.

### Список источников / References

1. Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008), A review on buildings energy consumption information Energy and Buildings, 40(3), 394—398.
2. Barak, S., & Sadeh, S.S. (2016), Forecasting energy consumption using ensemble ARIMA—ANFIS hybrid algorithm International Journal of Electrical Power & Energy Systems, 82, 92—104.
3. Demirbas, A. (2005), potential applications of renewable energy sources, biomass combustion problems in boiler power systems and combustion related environmental issues, progress in Energy and Combustion Science, 31(2), 171—192.
4. Zhao, H.-X., & Magoulès, F. (2012), A review on the prediction of building energy consumption Renewable and Sustainable Energy Reviews, 16(6), 3586—3592.
5. Ekici, B.B., & Aksoy, U.T. (2009), prediction of building energy consumption by using artificial neural networks, Advances in Engineering Software, 40(5), 356—362.
6. Yilmazkaya, E., et al. (2018), prediction of mono-wire cutting machine performance parameters using artificial neural network and regression models, Engineering Geology, 239, 96—108.
7. Zhang, W., & Yang, J. (2015), Forecasting natural gas consumption in China by Bayesian model averaging, Energy Reports, 1, 216—220, H
8. Abdoli, B., et al. (2018), Evaluation of the air-borne ultrasound on fluidized bed drying of shelled corn: Effectiveness, grain quality, and energy consumption, Drying Technology, 36(14), 1749—1766.
9. Abramovich, B.N., & Babanova, I.S. (2018), Development of neural network models to predict and control power consumption in mineral mining industry, Mining Informational and Analytical Bulletin, 2018(5), 206—213.
10. Abtahi, T., et al. (2018), Accelerating Convolutional Neural Network with FFT on Embedded Hardware, IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 26(9), 1737—1749.
11. Abu Sharkh, M., & Shami, A. (2017), An evergreen cloud: Optimizing energy efficiency in heterogeneous cloud computing architectures. Vehicular Communications, 9, 199—210.
12. Acharya, S., & D'Mello, D.A. (2017), Energy and cost-efficient dynamic load balancing mechanism for resource provisioning in cloud computing, International Journal of Applied Engineering Research, 12(24), 15782—15790.
13. Acharya, S., & Tripathy, C.R. (2018), An ANFIS estimator-based data aggregation scheme, Energy Reports, 4, 124—132.



14. Adamović, V.M., et al. (2018), An artificial neural network approach for the estimation of the primary production of energy from municipal solid waste and its application to the Balkan countries, *Waste Management*, 78, 955–968.
15. Adnan, W.N.W.M., Dahlan, N.Y., & Musirin, I. (2017), Development of hybrid artificial neural network for quantifying energy saving using measurement and verification, *Indonesian Journal of Electrical Engineering and Computer Science*, 8(1), 137–145.
16. Aftab, M., et al. (2017), Automatic HVAC control with real-time occupancy recognition and simulation-guided model predictive control in low-cost embedded system *Energy and Buildings*, 154, 141–156.
17. Aghbashlo, M., et al. (2017), Fuzzy modeling and optimization of the synthesis of biodiesel from waste cooking oil (WCO) by a low power, high frequency piezo-ultrasonic reactor, *Energy*, 132, 65–78.
18. Aghbashlo, M., et al. (2019), multi-objective exergetic and technical optimization of a piezoelectric ultrasonic reactor applied to synthesize biodiesel from waste cooking oil (WCO) using soft computing techniques, *Fuel*, 235, 100–112.
19. Aghbashlo, M., Tabatabaei, M., & Hossein pour, S. (2018), on the exergoeconomic and exergoenvironmental evaluation and optimization of biodiesel synthesis from waste cooking oil (WCO) using a low power, high frequency ultrasonic reactor, *Energy Conversion and Management*, 164, 385–398.
20. Ahmad, M.W., et al. (2018), Deep highway networks and tree-based ensemble for predicting short-term building energy consumption, *Energies*, 11(12).
21. Ahmad, M.W., Mourshed, M., & Rezgui, Y. (2017), Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption, *Energy and Buildings*, 147, 77–89.

### ***Информация об авторах***

*Ахмад Али*, аспирант кафедры «автоматизированного проектирования и дизайна», ФГАОУ ВО «Национальный исследовательский технологический университет “МИСИС”», Россия, Москва. e-mail: ali-ahmad9.3@mail.ru

*Ляпунцова Елена Вячеславовна* — доктор технических наук, профессор ФГБОУ ВО «Московский государственный технический университет имени Н.Э. Баумана (Национальный исследовательский университет)» (МГТУ имени Н.Э. Баумана) Россия, 105005, Москва, улица 2-я Бауманская, д. 5, к.1. e-mail: lev86@bmstu.ru

### ***Information about the authors***

*Ahmad Ali*, graduate student of the Department of Computer-Aided Engineering and Design, University of Science and Technology «MISIS», Russia, Moscow. e-mail: ali-ahmad9.3@mail.ru

*Lyapunsova Elena Vyacheslavovna*, Doctor of Technical Sciences, Professor at Bauman Moscow State Technical University (National Research University) (Bauman Moscow State Technical University). Russia, 105005, Moscow, 2nd Baumanskaya Street, 5, room 1. e-mail: lev86@bmstu.ru



### ***Вклад авторов***

Ахмед Али — разработка идеи исследования; применение статистических, математических и иных методов анализа данных; сбор и обработка данных; визуализация результатов, применение статистических, математических или других методов для анализа данных; проведение эксперимента

Ляпунцова Елена Вячеславовна — аннотирование, написание и оформление рукописи; планирование и проведение исследования

Все авторы приняли участие в обсуждении результатов и согласовали окончательный текст рукописи.

### ***Contribution of the authors***

Ahmed Ali — development of research ideas; application of statistical, mathematical and other methods of data analysis; data collection and processing; visualization of results, application of statistical, mathematical or other methods for data analysis; conducting an experiment

Lyapunтова Elena Vyacheslavovna — annotation, writing and design of the manuscript; planning and conducting research

All authors participated in the discussion of the results and approved the final text of the manuscript.

Поступила в редакцию 04.06.2025

Поступила после рецензирования 18.06.2025

Принята к публикации 27.06.2025

Опубликована 30.09.2025

Received 2025.05.06

Revised 2025.05.13

Accepted 2025.05.25

Published 2025.09.30