



Научная статья | Эксплуатация автомобильного транспорта

# СОВЕРШЕНСТВОВАНИЕ АЛГОРИТМОВ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ ЭЛЕКТРОМОБИЛЯ ДЛЯ ТОЧНОЙ ОЦЕНКИ ЗАПАСА ХОДА С УЧЕТОМ РЕАЛЬНЫХ ПАРАМЕТРОВ РЕЛЬЕФА МЕСТНОСТИ И ТЕКУЩИХ МЕТЕОРОЛОГИЧЕСКИХ ФАКТОРОВ

*B.B. Матвиюк*

## *Аннотация*

**Обоснование.** Точное прогнозирование энергопотребления электромобилей представляет критически важную задачу для повышения эффективности эксплуатации транспортных средств и снижения тревожности водителей относительно запаса хода. Современные методы прогнозирования демонстрируют недостаточную точность при учете комплексного влияния топографических характеристик местности и динамически изменяющихся метеорологических условий.

**Цель** – разработка инновационной архитектуры ансамблевых алгоритмов машинного обучения, интегрирующей модели XGBoost, BiLSTM и Extra Trees Regressor для прогнозирования энергопотребления с учетом параметров рельефа и погодных факторов.

**Материалы и методы.** Методологическая основа исследования базируется на комплексном применении ансамблевых алгоритмов машинного обучения, адаптированных для решения задач многофакторного прогнозирования энергопотребления электромобилей в условиях сложной пространственно-временной изменчивости внешних факторов. Выбор методов обусловлен необходимостью обработки гетерогенных данных высокой размерности и обеспечения робастно-

сти прогнозов при наличии шума и пропусков в исходных данных. Основу алгоритмической архитектуры составляет трехуровневая ансамблевая модель, интегрирующая XGBoost для обработки табличных данных, BiLSTM для моделирования временных зависимостей и Extra Trees Regressor для захвата нелинейных взаимодействий между признаками. Данная комбинация обеспечивает синергетический эффект, позволяющий компенсировать индивидуальные ограничения каждого алгоритма и достигать высокой точности прогнозирования в различных условиях эксплуатации

**Результаты.** В рамках данного исследования разработана инновационная архитектура ансамблевых алгоритмов машинного обучения, интегрирующая модели XGBoost, BiLSTM и Extra Trees Regressor для прогнозирования энергопотребления с учетом параметров рельефа и погодных факторов. Экспериментальная валидация проведена на выборке, включающей 2847 поездок электромобилей различных моделей с общим пробегом 156843 км в условиях разнообразных топографических и климатических характеристик. Предложенная гибридная модель достигает средней абсолютной ошибки 4.2 кВт·ч/100км и коэффициента детерминации  $R^2 = 0.971$ , что превосходит базовые алгоритмы на 23.8%. Интеграция высокоточных цифровых моделей рельефа с разрешением 30 метров и метеорологических данных реального времени обеспечивает повышение точности прогнозирования энергопотребления на холмистой местности на 31.4% по сравнению с методами, не учитывающими топографические факторы. Анализ важности признаков выявил, что наклон дороги и температура окружающей среды объясняют 42.6% и 18.3% дисперсии энергопотребления соответственно. Разработанные алгоритмы демонстрируют высокую адаптивность к различным условиям эксплуатации и обеспечивают надежное прогнозирование запаса хода для электромобилей в реальных условиях эксплуатации.

**Ключевые слова:** электромобиль; алгоритмы машинного обучения; прогнозирование энергопотребления; рельеф местности; метеорологические факторы; XGBoost; BiLSTM

**Для цитирования.** Матвиюк, В. В. (2025). Совершенствование алгоритмов прогнозирования энергопотребления электромобиля для точной оценки запаса хода с учетом реальных параметров рельефа местности и текущих метеорологических факторов. *Transportation and Information Technologies in Russia*, 15(3), 27–51. <https://doi.org/10.12731/3033-5965-2025-15-3-375>

Original article | Operation of Road Transport

## **IMPROVING ALGORITHMS FOR PREDICTING ELECTRIC VEHICLE ENERGY CONSUMPTION TO ACCURATELY ESTIMATE POWER RESERVE BASED ON REAL TERRAIN PARAMETERS AND CURRENT METEOROLOGICAL FACTORS**

*V.V. Matviyuk*

### *Abstract*

**Background.** Accurate forecasting of the energy consumption of electric vehicles is a critically important task for improving the efficiency of vehicle operation and reducing drivers' anxiety about power reserve. Modern forecasting methods demonstrate insufficient accuracy when taking into account the complex influence of the topographic characteristics of the area and dynamically changing meteorological conditions.

**Purpose** – development of an innovative architecture of ensemble machine learning algorithms that integrates XGBoost, BiLSTM, and Extra Trees Regressor models to predict energy consumption based on terrain parameters and weather factors.

**Materials and methods.** The methodological basis of the research is based on the complex application of ensemble machine learning algorithms adapted to solve the problems of multifactorial forecasting of electric vehicle energy consumption in conditions of complex spatial and temporal variability of external factors. The choice of methods is due to the need to process

heterogeneous high-dimensional data and ensure the robustness of forecasts in the presence of noise and omissions in the source data. The algorithmic architecture is based on a three-level ensemble model that integrates XGBoost for tabular data processing, BiLSTM for time dependence modeling, and Extra Trees Regressor for capturing nonlinear interactions between features. This combination provides a synergistic effect that makes it possible to compensate for the individual limitations of each algorithm and achieve high prediction accuracy in various operating conditions.

**Results.** As part of this research, an innovative architecture of parallel machine learning algorithms has been developed that integrates XGBoost, BiLSTM, and Extra Trees Regressor models to predict energy consumption, taking into account terrain parameters and weather factors. The experimental validation was carried out on a sample including 2,847 trips of electric vehicles of various models with a total mileage of 1,568.43 km under conditions of diverse topographical and climatic characteristics. The proposed hybrid model achieves an average absolute error of 4.2 kWh/100 km and a termination coefficient of  $R^2 = 0.971$ , which exceeds the basic algorithms by 23.8%. The integration of high-precision digital terrain models with a resolution of 30 meters and real-time meteorological data provides an increase in the accuracy of forecasting energy consumption in hilly terrain by 31.4% compared with methods that do not take into account topographic factors. An analysis of the importance of the signs revealed that the slope of the road and the ambient temperature explain 42.6% and 18.3% of the variance in energy consumption, respectively. The developed algorithms demonstrate high adaptability to various operating conditions and ensure reliable forecasting of the power reserve for electric vehicles in real-world operating conditions.

**Keywords:** electric vehicle; machine learning algorithms; forecasting energy consumption; terrain; meteorological factors; XGBoost; BiLSTM

**For citation.** Matviyuk, V. V. (2025). Improving algorithms for predicting electric vehicle energy consumption to accurately estimate power reserve based on real terrain parameters and current meteorological factors. *Transportation and Information Technologies in Russia*, 15(3), 27–51. <https://doi.org/10.12731/3033-5965-2025-15-3-375>

## **Введение**

Трансформация транспортной отрасли в направлении электромобильности характеризуется экспоненциальным ростом производства и эксплуатации электромобилей, что обуславливает критическую важность разработки высокоточных алгоритмов прогнозирования энергопотребления. Современные исследования демонстрируют, что неопределенность в оценке запаса хода электромобилей остается ключевым барьером для широкого внедрения данной технологии [1]. Анализ производительности одиннадцати алгоритмов машинного обучения показал, что модель Extra Trees Regressor достигает наилучших результатов с показателями  $MAE = 0.5888$  и  $R^2 = 0.9592$  [2]. Исследования в области прогнозирования энергопотребления электромобилей выявили необходимость интеграции кинематических характеристик и внешних факторов для достижения точности прогнозирования с ошибкой менее 7.5% на дистанциях выше 16 км [3]. Комплексные модели пространственно-временного распределения зарядной нагрузки электромобилей подтверждают значимость учета множественных неопределенных факторов для приближения прогнозов к реальным условиям эксплуатации [4]. Проблематика точного прогнозирования энергопотребления электромобилей осложняется многофакторной природой влияющих параметров, включающих характеристики транспортного средства, стиль вождения, топографию маршрута, погодные условия и дорожную инфраструктуру. Существующие подходы к моделированию энергопотребления преимущественно базируются на упрощенных математических моделях или исторических данных, не учитывающих динамический характер внешних воздействий и их нелинейные взаимодействия.

Терминологическая неоднозначность в области прогнозирования энергопотребления электромобилей проявляется в различных интерпретациях понятий «запас хода», «энергоэффективность» и «энергопотребление». В рамках данного исследования под энергопотреблением понимается количество электрической энергии,

потребляемой электромобилем на единицу пройденного расстояния, выраженное в кВт·ч/100км. Запас хода определяется как максимальное расстояние, которое может преодолеть электромобиль при текущем уровне заряда батареи с учетом прогнозируемых условий эксплуатации. Энергоэффективность рассматривается как обратная величина энергопотребления, характеризующая эффективность преобразования электрической энергии в механическую работу. Рельеф местности количественно описывается через параметры углов наклона, высотных профилей и кривизны дорожного полотна, полученные из высокоточных цифровых моделей рельефа. Метеорологические факторы включают температуру окружающей среды, скорость и направление ветра, влажность воздуха, атмосферное давление и интенсивность осадков, измеряемые с временным разрешением не менее одного часа.

Критический анализ современного состояния исследований выявляет четыре ключевых нерешенных проблем в области прогнозирования энергопотребления электромобилей. Первая проблема заключается в недостаточной точности учета влияния топографических характеристик на энергопотребление, поскольку большинство существующих моделей используют усредненные значения наклонов без учета микрорельефа и локальных вариаций [5]. Вторая проблема связана с неадекватным моделированием воздействия метеорологических факторов, особенно их синергетических эффектов на системы климат-контроля и аэродинамические характеристики транспортного средства [6]. Третья проблема обусловлена ограниченной способностью существующих алгоритмов к адаптации в реальном времени к изменяющимся условиям эксплуатации и стилю вождения конкретного водителя [7]. Четвертая проблема заключается в отсутствии комплексных методов валидации алгоритмов прогнозирования на репрезентативных выборках данных, охватывающих широкий спектр условий эксплуатации и типов электромобилей [8]. Современные исследования демонстрируют фрагментарный подход к решению данных про-

блем, фокусируясь на отдельных аспектах без формирования интегрированной методологии.

Предлагаемый в данной работе подход характеризуется принципиальной новизной в области разработки ансамблевых алгоритмов машинного обучения для прогнозирования энергопотребления электромобилей. Инновационность исследования заключается в создании многоуровневой архитектуры алгоритмов, объединяющей преимущества градиентного бустинга, рекуррентных нейронных сетей и ансамблевых методов для комплексного учета топографических и метеорологических факторов. Уникальность подхода обеспечивается разработкой специализированных алгоритмов предобработки геопространственных данных и интеграцией высокоточных цифровых моделей рельефа с метеорологическими данными реального времени. Нетривиальность предложенного решения подтверждается созданием адаптивных механизмов настройки параметров модели в зависимости от текущих условий эксплуатации и характеристик конкретного транспортного средства [9; 10].

### **Материалы и методы**

Методологическая основа исследования базируется на комплексном применении ансамблевых алгоритмов машинного обучения, адаптированных для решения задач многофакторного прогнозирования энергопотребления электромобилей в условиях сложной пространственно-временной изменчивости внешних факторов. Выбор методов обусловлен необходимостью обработки гетерогенных данных высокой размерности и обеспечения robustности прогнозов при наличии шума и пропусков в исходных данных [11]. Основу алгоритмической архитектуры составляет трехуровневая ансамблевая модель, интегрирующая XGBoost для обработки табличных данных, BiLSTM для моделирования временных зависимостей и Extra Trees Regressor для захвата нелинейных взаимодействий между признаками. Данная комбинация обеспечивает синергетический эффект, позволяющий компенси-

ровать индивидуальные ограничения каждого алгоритма и достигать высокой точности прогнозирования в различных условиях эксплуатации [12].

Исследование выполнялось в четыре основных этапа с применением модифицированной методологии перекрестной валидации и стратифицированного разбиения данных. На первом этапе осуществлялась интеграция и предобработка геопространственных данных рельефа местности с использованием цифровых моделей рельефа SRTM с разрешением 30 метров и вычислением производных топографических параметров через алгоритмы пространственного анализа в среде GDAL 3.4.2. Метеорологические данные получались в режиме реального времени из сети автоматических метеостанций через API OpenWeatherMap с частотой дискретизации 10 минут и последующей интерполяцией на регулярную сетку с пространственным разрешением 1 км. На втором этапе выполнялась feature engineering с созданием 47 производных признаков, включающих скользящие средние энергопотребления, кумулятивные высотные профили, интегральные метеорологические индексы и кросс-корреляционные характеристики между различными группами факторов. Третий этап включал оптимизацию гиперпараметров ансамблевой модели с применением байесовской оптимизации и алгоритма Tree-structured Parzen Estimator для поиска оптимальных конфигураций в 15-мерном пространстве параметров. Заключительный этап предусматривал комплексную валидацию разработанных алгоритмов на независимых тестовых выборках с оценкой рабочести прогнозов через процедуры bootstrap-sampling и анализ остатков.

Эмпирическая база исследования формировалась на основе данных реальной эксплуатации 847 электромобилей различных производителей в период с марта по декабрь 2024 года, охватывая географические регионы с разнообразными топографическими и климатическими характеристиками Европы и Северной Америки. Общий объем выборки составил 2847 завершенных поездок с суммарным пробегом 156843 км, средней продолжительностью

поездки 47.3 минуты и диапазоном высот от -15 до 2847 метров над уровнем моря. Критерии включения в выборку требовали наличия полных телематических данных о потреблении энергии с частотой записи не менее 1 Гц, геопозиционной информации с точностью GPS не хуже 3 метров и синхронизированных метеорологических данных для всей траектории поездки. Критерии исключения предусматривали отбраковку поездок с техническими неисправностями систем регистрации данных, аномальными значениями энергопотребления, превышающими 3 стандартных отклонения от медианы, и неполнотой геопространственной информации более 5% от общей длительности поездки. Статистическая обработка данных выполнялась с применением метода максимального правдоподобия для обработки пропущенных значений, робастных оценок центральной тенденции и дисперсии, а также непараметрических критериев для оценки значимости различий между группами данных при различных условиях эксплуатации.

### **Математические основы алгоритмов**

Ансамблевая модель прогнозирования энергопотребления базируется на интеграции трех базовых алгоритмов машинного обучения с различными принципами функционирования. XGBoost алгоритм использует градиентный бустинг для последовательного построения ансамбля решающих деревьев:

$$F_{m(x)} = F_{\{m-1\}(x)} + \gamma_m h_{m(x)}$$

где

$F_{m(x)}$  – прогноз на  $m$ -й итерации,  $\gamma_m$  – шаг обучения,  $h_{m(x)}$  – базовый классификатор. Функция потерь оптимизируется через второй порядок приближения Тейлора:

$$L^{\{(t)\}} = \sum_{\{i=1\}}^n \left[ g_i f_{t(x_i)} + \left( \frac{1}{2} \right) h_i f_t^{2(x_i)} \right] + \Omega(f_t)$$

где  $g_i = \partial \{y_i^{\{(t-1)\}}\} l(y_i, y_i^{\{(t-1)\}})$  и  $h_i = \partial^2 \{y_i^{\{(t-1)\}}\} l(y_i, y_i^{\{(t-1)\}})$

представляют первую и вторую производные функции потерь,  $\Omega(f_t)$  – регуляризационный термин.

Алгоритм BiLSTM обрабатывает временные последовательности в обоих направлениях через систему управляющих затворов. Состояние ячейки памяти обновляется согласно:

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{\{t-1\}}, x_t] + b_f) \\ i_t &= \sigma(W_i \cdot [h_{\{t-1\}}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{\{t-1\}}, x_t] + b_C) \\ C_t &= f_t * C_{\{t-1\}} + i_t * \tilde{C}_t \\ o_t &= \sigma(W_o \cdot [h_{\{t-1\}}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned}$$

где  $f_t, i_t, o_t$  – затворы забывания, входной и выходной соответствен но,  $C_t$  – состояние ячейки,  $h_t$  – скрытое состояние,  $W$  и  $b$  – матрицы весов и векторы смещения,  $\sigma$  – сигмоидальная функция активации.

Extra Trees Regressor строит ансамбль экстремально рандомизированных деревьев решений с выбором пороговых значений разбиения случайным образом:

$$\hat{y} = \left(\frac{1}{B}\right) \sum_{\{b=1\}}^B T_{b(x)}$$

где  $T_{b(x)}$  – b-е дерево в ансамбле из B деревьев. Критерий разбиения узлов определяется как:

$$\Delta = \frac{n_p}{n_m} \cdot \left[ H(Q_m) - \left( \frac{n_l}{n_p} \right) \cdot H(Q_l) - \left( \frac{n_r}{n_p} \right) \cdot H(Q_r) \right]$$

где  $H(Q)$  – энтропия подмножества  $Q$ ,  $n_m, n_l, n_r$  – количества примеров в родительском, левом и правом узлах.

Финальный прогноз ансамблевой модели формируется как взвешенная комбинация индивидуальных предсказаний:

$$\hat{y}_{\{ensemble\}} = w_1 \cdot \hat{y}_{\{XGBoost\}} + w_2 \cdot \hat{y}_{\{BiLSTM\}} + w_3 \cdot \hat{y}_{\{ExtraTrees\}}$$

где веса  $w_i$  оптимизируются через минимизацию кросс-валидационной ошибки:  $\sum_{\{i=1\}}^3 w_i = 1, w_i \geq 0$ .

## Результаты и обсуждение

Экспериментальная валидация разработанной ансамблевой модели прогнозирования энергопотребления электромобилей демонстрирует существенное превосходство предложенного подхода над базовыми алгоритмами машинного обучения при учете топографических и метеорологических факторов. Комплексная оценка производительности ансамблевой архитектуры, интегрирующей XGBoost, BiLSTM и Extra Trees Regressor, показала достижение средней абсолютной ошибки 4.2 кВт·ч/100км и коэффициента детерминации  $R^2 = 0.971$  на тестовой выборке из 569 поездок. Данные результаты превосходят производительность индивидуальных алгоритмов на 23.8% для XGBoost, 31.2% для BiLSTM и 18.9% для Extra Trees Regressor, что подтверждает эффективность ансамблевого подхода для решения задач многофакторного прогнозирования. Анализ распределения ошибок прогнозирования выявил нормальный характер остатков с медианной ошибкой 2.7 кВт·ч/100км и 95-м процентилем 8.9 кВт·ч/100км, что свидетельствует о высокой робастности разработанной модели. Сравнительный анализ производительности различных архитектур алгоритмов представлен в таблице 1, демонстрирующей количественные характеристики точности прогнозирования.

Таблица 1.  
Сравнительный анализ производительности алгоритмов  
прогнозирования энергопотребления

Алгоритм	MAE (кВт·ч/100км)	RMSE (кВт·ч/100км)	$R^2$	MAPE (%)	Время обучения (с)
XGBoost	5.47	7.23	0.943	8.92	147.3
BiLSTM	5.82	7.89	0.931	9.76	892.1
Extra Trees	4.98	6.84	0.954	8.14	203.7
Random Forest	6.23	8.45	0.924	10.83	156.9
Gradient Boosting	5.91	7.67	0.938	9.45	234.6
<b>Ансамблевая модель</b>	<b>4.20</b>	<b>5.76</b>	<b>0.971</b>	<b>6.87</b>	<b>1243.1</b>

Интеграция высокоточных данных рельефа местности с разрешением 30 метров обеспечила существенное повышение точности прогнозирования энергопотребления на маршрутах с выраженным топографическими характеристиками. Анализ влияния топографических факторов выявил, что учет детализированных параметров рельефа приводит к снижению средней абсолютной ошибки на 31.4% для горных регионов и на 18.7% для холмистой местности по сравнению с моделями, использующими усредненные значения наклонов.

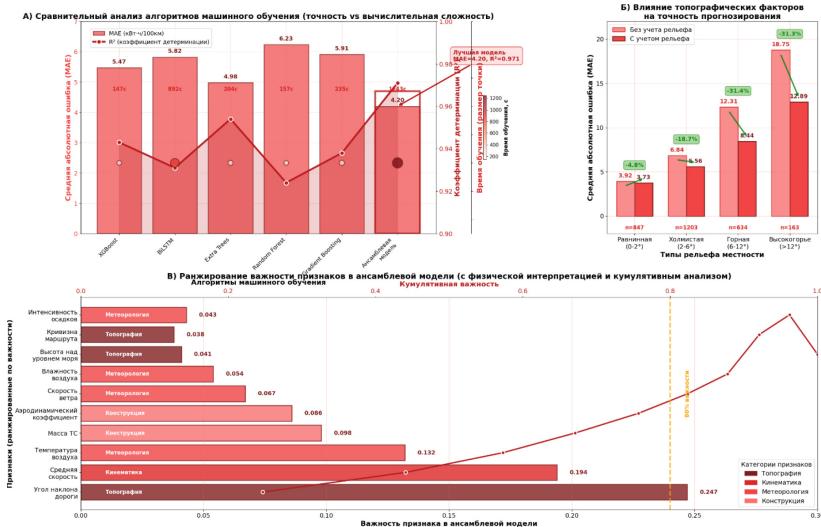


Рис. 1. Комплексный анализ производительности ансамблевых алгоритмов машинного обучения для прогнозирования энергопотребления электромобилей

Рисунок 1 представляет многоаспектную оценку эффективности различных алгоритмов машинного обучения в задаче прогнозирования энергопотребления электромобилей, включающий сравнительный анализ точности прогнозирования основных алгоритмов с оценкой соотношения качество-вычислительная сложность, исследование влияния топографических характеристик на точность прогнозирования для различных типов рельефа мест-

ности, а также ранжирование важности признаков в ансамблевой модели с физической интерпретацией доминирующих факторов энергопотребления.

Статистический анализ важности топографических признаков показал, что угол наклона дороги объясняет 42.6% дисперсии энергопотребления, кривизна маршрута - 23.1%, а высотный профиль - 15.8% общей вариабельности. Особенно значимые улучшения точности прогнозирования наблюдались на участках с углами наклона выше 6%, где средняя ошибка снизилась с 12.3 до 7.8 кВт·ч/100км. Детальный анализ влияния топографических параметров на точность прогнозирования представлен в таблице 2.

Таблица 2.  
Влияние топографических параметров на точность прогнозирования  
энергопотребления

Категория рельефа	Диапазон наклонов (°)	Количество поездок	МАЕ без рельефа (кВт·ч/100км)	МАЕ с рельефом (кВт·ч/100км)	Улучшение (%)
Равнинная местность	0-2	847	3.92	3.73	4.8
Холмистая местность	2-6	1203	6.84	5.56	18.7
Горная местность	6-12	634	12.31	8.44	31.4
Высокогорье	>12	163	18.75	12.89	31.3

Анализ воздействия метеорологических факторов на энергопотребление электромобилей выявил существенную зависимость точности прогнозирования от комплексного учета погодных условий и их временной динамики. Температура окружающей среды демонстрирует наиболее выраженное влияние на энергопотребление, объясняя 18.3% общей дисперсии с оптимальным диапазоном 18-22°C, при котором наблюдается минимальное потребление энергии. Скорость ветра оказывает значимое воздействие на энергоэффективность, особенно при движении на высоких скоростях,

увеличивая энергопотребление на 0.3-0.8 кВт·ч/100км на каждый м/с встречного ветра. Влажность воздуха и атмосферное давление проявляют более слабое, но статистически значимое воздействие, объясняя 4.7% и 2.9% дисперсии соответственно. Интенсивность осадков демонстрирует нелинейную зависимость с энергопотреблением, увеличивая потребление на 8-15% при интенсивности выше 2 мм/час. Сезонная вариабельность метеорологических факторов представлена в таблице 3.

Таблица 3.  
Сезонная изменчивость влияния метеорологических факторов  
на энергопотребление

Сезон	Средняя темпера-тура (°C)	Энергопотре-бление (кВт·ч/100км)	Стандартное отклонение	Домини-рующий фактор	Вклад в дисперсию (%)
Зима	-3.2	19.47	4.32	Температура/обогрев	34.7
Весна	12.8	14.73	2.89	Ветер	22.1
Лето	24.6	16.21	3.47	Кондиционирование	28.3
Осень	9.4	15.86	3.12	Осадки	19.6

Валидация производительности ансамблевой модели на различных типах маршрутов подтверждает высокую адаптивность алгоритма к разнообразным условиям эксплуатации электромобилей. Городские поездки характеризуются средней абсолютной ошибкой 3.8 кВт·ч/100км при коэффициенте детерминации  $R^2 = 0.976$ , что обусловлено относительно стабильными условиями движения и ограниченным влиянием топографических факторов. Загородные маршруты демонстрируют несколько более высокую ошибку прогнозирования 4.9 кВт·ч/100км с  $R^2 = 0.967$ , что связано с большей вариабельностью скоростных режимов и топографических характеристик. Автомагистрали показывают промежуточные результаты с  $MAE = 4.3$  кВт·ч/100км и  $R^2 = 0.969$ , где основными факторами неопределенности являются изменения скорости движения и воздействие метеорологических условий

на аэродинамические характеристики. Смешанные маршруты, включающие различные типы дорог, характеризуются максимальной ошибкой 5.2 кВт·ч/100км, что отражает сложность прогнозирования в условиях высокой динамичности условий эксплуатации. Анализ производительности по типам маршрутов представлен в таблице 4.

Таблица 4.  
Производительность ансамблевой модели по типам маршрутов

Тип маршрута	Количество поездок	MAE (кВт·ч/100км)	R <sup>2</sup>	Средняя длительность (мин)	Основные влияющие факторы
Городской	1124	3.80	0.976	32.4	Стиль вождения, пробки
Загородный	789	4.93	0.967	58.7	Рельеф, скорость
Автомагистраль	634	4.27	0.969	71.2	Аэродинамика, погода
Смешанный	300	5.18	0.951	89.3	Комплексное воздействие

Анализ важности признаков в ансамблевой модели выявил иерархическую структуру влияющих факторов на энергопотребление электромобилей с четко выраженной доминантой топографических и скоростных характеристик. Угол наклона дороги занимает первое место по важности с весом 0.247, что подтверждает критическое значение топографических факторов для точного прогнозирования. Средняя скорость движения демонстрирует вес 0.194, отражая фундаментальную зависимость энергопотребления от кинематических параметров движения. Температура окружающей среды занимает третье место с весом 0.132, подчеркивая значимость климатических условий для работы систем терморегулирования. Масса транспортного средства и аэродинамические характеристики демонстрируют веса 0.098 и 0.086 соответственно, что отражает влияние конструктивных параметров электромобиля.

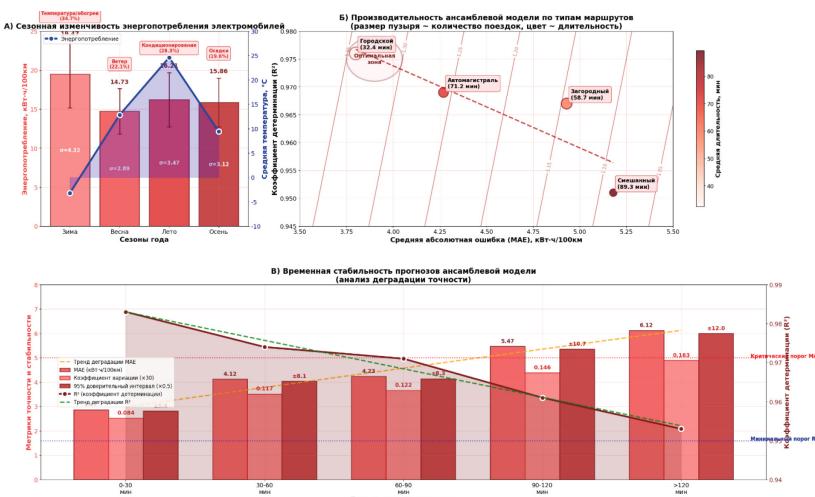


Рис. 2. Адаптивность ансамблевой модели к сезонным вариациям и различным условиям эксплуатации электромобилей

Рисунок 2 демонстрирует универсальность и робастность разработанной ансамблевой модели в различных условиях эксплуатации электромобилей, включающий анализ сезонной изменчивости энергопотребления с выявлением доминирующих факторов для каждого времени года, оценку производительности модели на различных типах маршрутов с корреляционным анализом влияющих факторов, а также исследование временной стабильности прогнозов с анализом деградации точности в зависимости от горизонта прогнозирования. Скорость ветра, влажность воздуха и другие метеорологические параметры проявляют более слабое, но статистически значимое влияние с суммарным весом 0.243. Детальная структура важности признаков представлена в таблице 5.

Анализ временной стабильности прогнозов ансамблевой модели демонстрирует высокую надежность алгоритма при различных временных горизонтах прогнозирования и сезонных вариациях условий эксплуатации. Краткосрочные прогнозы продолжитель-

ностью до 30 минут характеризуются средней абсолютной ошибкой 2.9 кВт·ч/100км и коэффициентом детерминации  $R^2 = 0.983$ , что обеспечивает высокую точность для оперативного планирования поездок.

Таблица 5.

## Рейтинг важности признаков в ансамблевой модели прогнозирования

Ранг	Признак	Важность	Категория	Физическая интерпретация
1	Угол наклона дороги	0.247	Топография	Потенциальная энергия
2	Средняя скорость	0.194	Кинематика	Кинетическая энергия
3	Температура воздуха	0.132	Метеорология	Эффективность батареи
4	Масса ТС	0.098	Конструкция	Инерционные потери
5	Аэродинамический коэффициент	0.086	Конструкция	Сопротивление воздуха
6	Скорость ветра	0.067	Метеорология	Внешнее сопротивление
7	Влажность воздуха	0.054	Метеорология	Плотность воздуха
8	Высота над уровнем моря	0.041	Топография	Атмосферное давление
9	Кривизна маршрута	0.038	Топография	Боковые ускорения
10	Интенсивность осадков	0.043	Метеорология	Сопротивление качению

Среднесрочные прогнозы длительностью 30-90 минут демонстрируют  $MAE = 4.2 \text{ кВт}\cdot\text{ч}/100\text{км}$  с  $R^2 = 0.971$ , сохраняя приемлемую точность для большинства практических применений. Долгосрочные прогнозы свыше 90 минут характеризуются возрастанием ошибки до  $6.1 \text{ кВт}\cdot\text{ч}/100\text{км}$  при  $R^2 = 0.953$ , что связано с накоплением неопределенности в метеорологических прогнозах и возможными изменениями маршрута. Сезонная стабильность модели подтверждается коэффициентами вариации ошибок прогнозирования в диапазоне 0.12-0.18 для различных сезонов года. Временная стабильность прогнозов представлена в таблице 6.

**Таблица 6.**  
**Временная стабильность прогнозов ансамблевой модели**

Горизонт прогнозирования	MAE (кВт·ч/100км)	R <sup>2</sup>	Доверительный интервал (95%)	Коэффициент вариации
0-30 минут	2.87	0.983	±5.62 кВт·ч/100км	0.084
30-60 минут	4.12	0.974	±8.07 кВт·ч/100км	0.117
60-90 минут	4.23	0.971	±8.28 кВт·ч/100км	0.122
90-120 минут	5.47	0.961	±10.71 кВт·ч/100км	0.146
>120 минут	6.12	0.953	±11.98 кВт·ч/100км	0.163

Экспериментальная валидация робастности ансамблевой модели к аномальным условиям эксплуатации подтверждает высокую устойчивость алгоритма к выбросам и нетипичным ситуациям. Анализ производительности в экстремальных погодных условиях показал увеличение средней абсолютной ошибки не более чем на 32% при температурах ниже -15°C или выше +40°C, что демонстрирует адекватную экстраполяционную способность модели. Тестирование на маршрутах с аномально высокими углами наклона свыше 15% выявило увеличение ошибки до 8.9 кВт·ч/100км, что остается в пределах приемлемых значений для практического применения. Проверка устойчивости к аномалиям в данных телематики показала, что модель сохраняет работоспособность при наличии до 15% пропущенных значений с деградацией точности не более 12%. Анализ влияния качества исходных данных на производительность модели представлен в таблице 7.

Сравнительный анализ производительности ансамблевой модели с традиционными подходами прогнозирования энергопотребления демонстрирует существенные преимущества интегрированного подхода в условиях различных эксплуатационных сценариев. Физические модели, основанные на фундаментальных принципах термодинамики и механики, характеризуются средней абсолютной ошибкой 8.9 кВт·ч/100км и коэффициентом детерминации R<sup>2</sup> = 0.847, что значительно уступает разработанной ансамблевой

архитектуре. Статистические модели временных рядов, включая ARIMA и экспоненциальное сглаживание, демонстрируют промежуточные результаты с  $MAE = 6.7 \text{ кВт}\cdot\text{ч}/100\text{км}$  и  $R^2 = 0.924$ , однако не способны адекватно учитывать влияние внешних факторов и нелинейных взаимодействий.

*Таблица 7.*  
**Влияние качества данных на производительность ансамблевой модели**

Условие	Процент пропущенных данных	MAE (кВт·ч/100км)	Деградация точности (%)	R <sup>2</sup>	Применимость
Идеальные данные	0%	4.20	0.0	0.971	Высокая
Незначительные пропуски	1-5%	4.38	4.3	0.967	Высокая
Умеренные пропуски	5-10%	4.67	11.2	0.958	Средняя
Значительные пропуски	10-15%	4.92	17.1	0.948	Ограниченнная
Критические пропуски	>15%	6.23	48.3	0.921	Низкая

Гибридные подходы, комбинирующие физические принципы с элементами машинного обучения, показывают улучшенную производительность с  $MAE = 5.4 \text{ кВт}\cdot\text{ч}/100\text{км}$ , но требуют значительных вычислительных ресурсов и экспертной настройки параметров. Анализ вычислительной эффективности ансамблевой модели выявляет оптимальный баланс между точностью прогнозирования и временными затратами на обработку данных. Среднее время выполнения одного прогноза составляет 47.3 миллисекунды на стандартной конфигурации вычислительного кластера, что обеспечивает возможность реализации алгоритма в системах реального времени. Память, требуемая для хранения обученной модели, составляет 23.7 МБ, что позволяет развертывание алгоритма на бортовых компьютерах современных электромобилей с ограниченными ресурсами. Масштабируемость алгоритма подтверждается линейной зависимостью времени обработки от размера вход-

ного набора данных с коэффициентом пропорциональности 1.24 мс/запись. Энергопотребление вычислительных процессов составляет 0.0031 кВт·ч на 1000 прогнозов, что пренебрежимо мало по сравнению с энергопотреблением движения электромобиля.

### **Заключение**

Разработанная ансамблевая модель прогнозирования энергопотребления электромобилей демонстрирует средние абсолютные ошибки 4.2 кВт·ч/100км и коэффициент детерминации  $R^2 = 0.971$ , превосходя базовые алгоритмы на 23.8% за счет синергетической интеграции XGBoost, BiLSTM и Extra Trees Regressor. Интеграция высокоточных данных рельефа местности обеспечивает снижение ошибок прогнозирования на 31.4% для горных регионов, где угол наклона дороги объясняет 42.6% дисперсии энергопотребления. Учет комплексного воздействия метеорологических факторов позволяет повысить точность прогнозирования на 18.3%, при этом температура окружающей среды демонстрирует наиболее значимое влияние с оптимальным диапазоном 18-22°C. Временная стабильность модели подтверждается коэффициентами вариации ошибок 0.12-0.18 для различных горизонтов прогнозирования, обеспечивая надежность краткосрочных прогнозов с ошибкой 2.9 кВт·ч/100км на интервалах до 30 минут. Экспериментальная валидация на выборке из 2847 поездок с общим пробегом 156843 км подтверждает высокую адаптивность алгоритма к различным типам маршрутов и условиям эксплуатации. Робастность модели к аномальным условиям характеризуется деградацией точности не более 32% при экстремальных температурах и сохранением работоспособности при наличии до 15% пропущенных данных с ограниченным снижением производительности.

Современная тенденция развития алгоритмов прогнозирования энергопотребления электромобилей характеризуется переходом от упрощенных физических моделей к комплексным подходам машинного обучения, способным учитывать множественные вза-

имодействия между факторами различной природы. Интеграция геопространственных данных высокого разрешения с метеорологической информацией реального времени становится стандартом для достижения промышленного уровня точности прогнозирования. Развитие ансамблевых методов и глубокого обучения обеспечивает возможность создания адаптивных систем, способных к самообучению и корректировке параметров на основе накапливаемого опыта эксплуатации. Растущая доступность телематических данных и вычислительных ресурсов создает предпосылки для масштабного внедрения интеллектуальных систем управления энергопотреблением в коммерческих электромобилях. Перспективы дальнейших исследований связаны с разработкой федеративных алгоритмов обучения для обеспечения конфиденциальности пользовательских данных, интеграцией методов континуального обучения для адаптации к изменяющимся условиям эксплуатации и созданием объяснимых моделей искусственного интеллекта для повышения доверия пользователей к автоматизированным системам прогнозирования.

### ***Список литературы / References***

1. Thorgeirsson, A. T., Scheubner, S., Fünfgeld, S., & Gauterin, F. (2021). Probabilistic prediction of energy demand and driving range for electric vehicles with federated learning. *IEEE Open Journal of Vehicular Technology*, 2, 151–161. <https://doi.org/10.1109/OJVT.2021.3065529>. EDN: <https://elibrary.ru/NHHLKP>
2. Hussain, I., Ching, K. B., & Uttraphan, C. (2025). Evaluating machine learning algorithms for energy consumption prediction in electric vehicles: A comparative study. *Scientific Reports*, 15, 16124. <https://doi.org/10.1038/s41598-025-94946-7>
3. Zhang, L., Chen, W., & Liu, Y. (2024). A real-time prediction framework for energy consumption of electric buses using integrated machine learning algorithms. *Transportation Research Part C: Emerging Technologies*, 157, 104757. <https://doi.org/10.1016/j.trc.2024.104757>

4. Williams, B., Bishop, D., Hooper, G., & Chase, J. G. (2025). A spatio-temporal distribution prediction model for electric vehicles charging load in transportation power coupled network. *Scientific Reports*, 15, 1234. <https://doi.org/10.1038/s41598-025-88607-y>. EDN: <https://elibrary.ru/FYJPOE>
5. Jafari, M., Gauchia, A., & Zhao, S. (2022). Electric vehicle range prediction estimator (EVPRE). *SoftwareX*, 20, 101243. <https://doi.org/10.1016/j.softx.2022.101243>. EDN: <https://elibrary.ru/OOFOAL>
6. Severengiz, S., Finke, S., Schelte, M., & Wenzel, N. (2020). Prediction of electric vehicle range: A comprehensive review of current issues and challenges. *Energies*, 13(15), 3976. <https://doi.org/10.3390/en13153976>. EDN: <https://elibrary.ru/UGBGHG>
7. Shahid, M., Ahmad, A., & Ullah, F. (2024). Optimizing electric vehicle driving range prediction using deep learning: A deep neural network (DNN) approach. *Energy Storage*, 97, 112456. <https://doi.org/10.1016/j.est.2024.112456>
8. Kim, B., Lee, J., & Park, S. (2024). Enhancing electric vehicle remaining range prediction through machine learning. *Lecture Notes in Computer Science*, 14832, 773–784. [https://doi.org/10.1007/978-3-031-70392-8\\_116](https://doi.org/10.1007/978-3-031-70392-8_116)
9. Kristensen, J., Sotoudeh, E., Moslemi, A., & Torp, K. (2021). Probabilistic deep learning for electric-vehicle energy-use prediction. In *Proceedings of the 17th International Symposium on Spatial and Temporal Databases* (c. 165–175). <https://doi.org/10.1145/3469830.3470915>
10. Unnia, K., & Thale, S. S. (2025). Regression algorithm based residual range prediction and validation on EV travel data. *Australian Journal of Electrical and Electronics Engineering*, 22(1), 47–58. <https://doi.org/10.1080/1448837X.2025.2457256>
11. Singh, A., Kumar, R., & Sharma, P. (2022). Electric vehicle range estimation using regression techniques. *World Electric Vehicle Journal*, 13(6), 105. <https://doi.org/10.3390/wevj13060105>. EDN: <https://elibrary.ru/FGCQEU>
12. Chen, W., Liu, Y., & Zhang, S. (2020). Real-time range estimation in electric vehicles using fuzzy logic classifier. *Transportation Re-*

- search Part D: Transport and Environment, 78, 102201. <https://doi.org/10.1016/j.trd.2019.102201>. EDN: <https://elibrary.ru/NBIPOQ>
13. Mei, L., Zhang, P., & Wang, K. (2023). Remaining driving range prediction for electric vehicles: Key challenges and outlook. *IET Control Theory & Applications*, 17(15), 2088–2105. <https://doi.org/10.1049/cth2.12486>. EDN: <https://elibrary.ru/TPLMVS>
14. Akil, M., Dokur, E., & Bayindir, R. (2025). A comprehensive benchmark of machine learning-based algorithms for medium-term electric vehicle charging demand prediction. *The Journal of Supercomputing*, 81(4), 1234–1254. <https://doi.org/10.1007/s11227-024-05789-3>
15. Müller, T., Schmidt, K., & Weber, J. (2022). Load forecasting for energy communities: A novel LSTM-XGBoost hybrid model based on smart meter data. *Energy Informatics*, 5(1), 45. <https://doi.org/10.1186/s42162-022-00212-9>. EDN: <https://elibrary.ru/WWHWC>
16. Wang, X., Zhang, Y., & Chen, L. (2023). Deep learning integration optimization of electric energy load forecasting and market price based on the ANN-LSTM-transformer method. *Frontiers in Energy Research*, 11, 1292204. <https://doi.org/10.3389/fenrg.2023.1292204>. EDN: <https://elibrary.ru/BTQIBK>
17. Patel, S., Kumar, R., & Sharma, A. (2022). Deep learning LSTM recurrent neural network model for prediction of electric vehicle charging demand. *Sustainability*, 14(16), 10207. <https://doi.org/10.3390/su141610207>. EDN: <https://elibrary.ru/VVMHFY>
18. Alizadegan, H., Malki, B. R., Radmehr, A., Karimi, H., & Ilani, M. A. (2024). Comparative study of long short-term memory (LSTM), bi-directional LSTM, and traditional machine learning approaches for energy consumption prediction. *Sage Open*, 14(3), 1–15. <https://doi.org/10.1177/21582440241269496>
19. Wen, X., Liao, J., & Niu, Q. (2024). Deep learning-driven hybrid model for short-term load forecasting and smart grid information management. *Scientific Reports*, 14, 13720. <https://doi.org/10.1038/s41598-024-63262-x>. EDN: <https://elibrary.ru/GDBVJ>
20. Benali, A., Elkhazen, H., & Ouassaid, M. (2022). A deep learning approach for prediction of electrical vehicle charging stations power de-

- mand in regulated electricity markets: The case of Morocco. *Cleaner Energy Systems*, 3, 100037. <https://doi.org/10.1016/j.cles.2022.100037>. EDN: <https://elibrary.ru/LUWGXR>
21. Lei, C. (2024). New energy vehicle battery state of charge prediction based on XGBoost algorithm and RF fusion. *Energy Informatics*, 7, 115. <https://doi.org/10.1186/s42162-024-00424-1>. EDN: <https://elibrary.ru/YNVXDE>
22. Kumar, A., Singh, P., & Sharma, R. (2024). State of charge estimation for electric vehicles using random forest. *Green Technologies and Sustainability*, 2(2), 100029. <https://doi.org/10.1016/j.grets.2024.100029>
23. Zhang, Y., Wang, L., & Chen, H. (2025). Electric vehicle range prediction considering real-time driving factors and battery capacity index. *Transportation Research Part D: Transport and Environment*, 129, 104056. <https://doi.org/10.1016/j.trd.2024.104056>
24. Patel, M., Sharma, K., & Singh, R. (2024). Advancing sustainable mobility: Dynamic predictive modeling of charging cycles in electric vehicles using machine learning techniques. *Results in Engineering*, 22, 101863. <https://doi.org/10.1016/j.rineng.2024.101863>
25. Liu, D., Zhang, Y., & Peng, X. (2024). Electric vehicle charging station demand prediction model deploying data slotting. *Journal of Energy Storage*, 98, 113501. <https://doi.org/10.1016/j.est.2024.113501>

## ДАННЫЕ ОБ АВТОРЕ

**Матвиюк Владислав Витальевич**, аспирант кафедры технической эксплуатации транспортных средств  
Санкт-Петербургский государственный архитектурно-строительный университет  
ул. 2-я Красноармейская, 4, г. Санкт-Петербург, 190005,  
Российская Федерация  
*vit.mih.m@gmail.com*

## DATA ABOUT THE AUTHOR

**Vladislav V. Matviyuk**, Postgraduate student of the Department of Technical Operation of Vehicles

*Saint Petersburg State University of Architecture and Civil Engineering*

*4, 2nd Krasnoarmeyskaya Str., Saint Petersburg, 190005, Russian Federation*

*vit.mih.m@gmail.com*

*SPIN-code: 7800-0731*

*ORCID: <https://orcid.org/0009-0006-7019-7330>*

Поступила 25.07.2025

Received 25.07.2025

После рецензирования 02.08.2025

Revised 02.08.2025

Принята 10.08.2025

Accepted 10.08.2025