

DOI: <https://doi.org/10.30898/1684-1719.2026.3.9>

УДК: 621.396.96.001 (07)

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЭФФЕКТИВНОСТИ НАВЕДЕНИЯ ЛЕТАТЕЛЬНОГО АППАРАТА ПО КАРТАМ РЕЛЬЕФА МЕСТНОСТИ КЛАССИЧЕСКИМИ МЕТОДАМИ И МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ НАЛИЧИИ НЕПРОГНОЗИРУЕМЫХ АРТЕФАКТНЫХ ИСКАЖЕНИЙ

Л.Г. Доросинский, А.А. Пономарев

**Уральский федеральный университет имени первого президента России Б.Н. Ельцина,
620002, Россия, Екатеринбург, ул. Мира, 19**

Статья поступила в редакцию 18 февраля 2026 г.

Аннотация. В работе проведен сравнительный анализ эффективности наведения летательного аппарата по картам рельефа местности с использованием классических корреляционно-экстремальных алгоритмов и методов искусственного интеллекта в условиях наличия непрогнозируемых артефактных искажений рельефа. Рельеф местности моделируется как стационарное случайное поле с локальными нестационарными возмущениями, отсутствующими в эталонной карте. Показано, что такие искажения приводят к нарушению статистических предположений, лежащих в основе классических методов навигации, и вызывают редкие, но критические навигационные сбои. Для адекватной оценки качества навигационных алгоритмов введен интегральный показатель навигационной надежности, определяемый как вероятность нахождения ошибки позиционирования ниже заданного порога. На основе численного моделирования выполнено сравнение методов по среднеквадратической ошибке, вероятности катастрофических сбоев и

вычислительной сложности. Показано, что методы искусственного интеллекта обладают более высокой навигационной надежностью в условиях непрогнозируемых искажений рельефа, тогда как классические алгоритмы сохраняют преимущество по точности и вычислительной эффективности в идеализированных условиях. Обоснована перспективность гибридных навигационных алгоритмов, сочетающих аналитические и обучаемые подходы.

Ключевые слова: навигация по рельефу, наведение ЛА, радиовысотомер, корреляционно-экстремальные алгоритмы, искусственный интеллект, машинное обучение, артефакты рельефа, навигационная надежность.

Автор для переписки: Доросинский Леонид Григорьевич, L.Dorosinsky@mail.ru

Введение

Наведение летательных аппаратов (ЛА) по картам рельефа местности является одним из ключевых направлений автономной навигации, особенно в условиях отсутствия или подавления спутниковых навигационных сигналов [1-3]. Подобные методы лежат в основе корреляционно-экстремальных систем навигации, широко известных по концепциям TERCOM и DSMAC, и продолжают развиваться с учетом роста вычислительных возможностей бортовых систем.

Классический подход к навигации по рельефу основан на сопоставлении измерений бортового радиовысотомера с эталонной цифровой картой высот. Предполагается, что рельеф является стационарным случайным полем с заданными корреляционными характеристиками, а расхождения между измерениями и картой носят ограниченный и предсказуемый характер [4].

Однако в реальных условиях данное предположение часто нарушается. В цифровых картах рельефа могут отсутствовать временные или локальные объекты, такие как инженерные сооружения, насыпные конструкции, изменения рельефа вследствие природных или антропогенных факторов. Кроме того,

данные высотомеров могут содержать артефакты измерений, вызванные многолучевостью, отражениями от искусственных объектов и шумами датчиков.

Подобные непрогнозируемые искажения приводят к существенному снижению эффективности классических корреляционных алгоритмов, поскольку они основаны на предположении согласованности статистических характеристик измеряемого и эталонного рельефов.

В последние годы в задачах навигации все более активно рассматриваются методы искусственного интеллекта, в частности нейронные сети глубокого обучения. Эти методы потенциально способны извлекать устойчивые пространственные признаки рельефа и игнорировать локальные аномалии, однако их применение сопровождается проблемами интерпретируемости и необходимостью больших обучающих выборок.

В связи с этим актуальной является задача комплексного сравнительного анализа классических и интеллектуальных методов наведения летательных аппаратов по рельефу местности с учетом не только точностных характеристик, но и показателей надежности функционирования [5]. Целью настоящей работы является исследование эффективности указанных подходов в условиях наличия непрогнозируемых артефактных искажений рельефа, а также разработка интегральных критериев оценки, позволяющих корректно учитывать риск катастрофических навигационных сбоев.

1. Математическая модель рельефа местности и непрогнозируемых искажений

Математическое моделирование рельефа местности является ключевым элементом задач навигации по данным радиовысотомера, поскольку именно свойства подстилающей поверхности определяют информативность измерений и потенциальную разрешающую способность навигационного алгоритма. В рамках настоящей работы рельеф рассматривается как случайный пространственный процесс, параметры которого выбираются таким образом, чтобы адекватно отражать статистические характеристики реальной земной

поверхности на масштабах, сопоставимых с характерными размерами траектории полета летательного аппарата.

Рельеф земной поверхности в области навигации летательного аппарата рассматривается как реализация двумерного случайного поля высот:

$$Z(x, y) \in R^2, \quad (1)$$

где x и y – декартовы координаты в горизонтальной плоскости, а Z – абсолютная высота рельефа относительно выбранного уровня отсчета.

В рамках классических подходов предполагается, что поле $Z(x, y)$ является двумерным стационарным и эргодическим случайным процессом, что позволяет описывать его статистические свойства с помощью математического ожидания

$$M[Z(x, y)] = \mu_Z \quad (2)$$

и ковариационной функции

$$R_Z(\Delta x, \Delta y) = M[(Z(x, y) - \mu_Z)((Z(x + \Delta x, y + \Delta y) - \mu_Z))]. \quad (3)$$

В большинстве практических моделей рельефа ковариационная функция принимается изотропной и зависит только от модуля смещения:

$$R_Z(\Delta x, \Delta y) = \sigma_Z^2 \rho(\sqrt{\Delta x^2 + \Delta y^2}), \quad (4)$$

где σ_Z^2 – дисперсия высот, а $\rho(r)$ – нормированная корреляционная функция.

Для целей навигации непрерывное поле $Z(x, y)$ дискретизируется на регулярной сетке с шагами Δx , Δy , что приводит к матрице высот:

$$Z_{i,j}(i\Delta x, j\Delta y) \quad i=1, \dots, Nx, \quad j=1, \dots, Ny. \quad (5)$$

Эталонная карта рельефа, хранящаяся в бортовой системе навигации, представляет собой фиксированную реализацию $N_{i,j}^{ref}$, полученную либо из данных дистанционного зондирования, либо из априорных цифровых моделей местности. Пример такого рельефа приведен на рисунке 1. Он иллюстрирует базовую модель рельефа без артефактных искажений.

Важно отметить, что даже при отсутствии искажений измерений эталонная карта и реальный рельеф не совпадают полностью из-за: ограниченного разрешения карты, сглаживания высокочастотных компонентов, ошибок интерполяции. Эти расхождения традиционно моделируются как аддитивный шум с малыми дисперсиями и учитываются в классических алгоритмах навигации.




Рис. 1. Пример реализации стационарного случайного рельефа.

Измерения бортового радиовысотомера представляются в виде последовательности

$$h_k = H_k - Z(x_k, y_k) + \epsilon_k. \quad (6)$$

где:

- H_k – абсолютная высота полета ЛА,
- x_k, y_k – текущая горизонтальная позиция,
- ϵ_k – шум измерений, обычно моделируемый как гауссовский белый:
- $\epsilon_k \sim N(0, \sigma_\epsilon^2)$

Таким образом, измерения высотомера фактически несут информацию о профиле рельефа вдоль траектории полета, что и используется в алгоритмах наведения.

2. Непрогнозируемые искажения рельефа (артефакты)

Ключевым отличием рассматриваемой в данной работе постановки задачи является введение непрогнозируемых искажений рельефа, отсутствующих в эталонной карте.

Фактический рельеф в области навигации представляется в виде

$$Z_{i,j}^{real}(x, y) = Z(x, y) + A(x, y), \quad (7)$$

где $A(x, y)$ – поле артефактных искажений.

В отличие от базового рельефа, поле $A(x, y)$ обладает следующими свойствами: нестационарность, локальность, отсутствие априорной информации о статистических характеристиках.

В численных экспериментах, результаты которых использованы далее в статье, артефакты моделировались в виде суммы локальных возмущений:

$$A(x, y) = \sum_{m=1}^M a_m \varnothing_m(x, y), \quad (8)$$

где:

- a_m – амплитуда артефакта,
- $\varnothing_m(x, y)$ – локализованная функция (например, гауссовский «бугор» или резкий разрыв высот),
- M – количество артефактов в области навигации.

Такая модель позволяет описывать: здания и инженерные сооружения, насыпные и выемочные элементы рельефа, резкие локальные ошибки цифровых карт. Следует отметить, что наличие даже небольшого числа артефактов приводит к существенному нарушению корреляционной структуры рельефа.

Добавление поля $A(x, y)$ приводит к изменению ключевых предположений классических алгоритмов навигации. В частности:

$$M[Z^{real}(x, y)] \neq \text{const}; \quad (9)$$

$$R_{Z^{real}}(\Delta x, \Delta y) \neq R_Z(\Delta x, \Delta y). \quad (10)$$

Корреляционная функция становится зависимой от абсолютного положения, а спектр мощности приобретает выраженные высокочастотные компоненты, отсутствующие в эталонной карте. Пример рельефа с артефактами приведен на рисунке 2.

Это приводит к снижению максимума корреляционного функционала и появлению ложных экстремумов, что непосредственно отражается на ошибках определения положения ЛА.




Рис. 2. Пример рельефа с локальными артефактными искажениями.

Сформулированная модель служит базой для дальнейшего анализа устойчивости классических методов и методов искусственного интеллекта, рассматриваемых в последующих разделах.

3. Классические алгоритмы наведения летательного аппарата по рельефу местности

Задача наведения летательного аппарата по рельефу местности формулируется как задача оценки текущего положения ЛА:

$$\hat{r}_k = (\hat{x}_k, \hat{y}_k)$$

на основе последовательности измерений радиовысотомера:

$$\{h_k\}_{k=1}^N$$

и априорной эталонной карты рельефа $Z^{ref}(x,y)$.

Предполагается, что абсолютная высота полета H_k известна с высокой точностью, а основной источник навигационной информации содержится в вариациях измеряемого профиля рельефа вдоль траектории движения.

В классических алгоритмах навигации оценка положения определяется как решение оптимизационной задачи вида

$$\hat{r}_k = \arg \max_r J(r, h_{1:k}, Z^{ref}), \quad (11)$$

J – некоторый критерий соответствия измерений эталонной карте.

Наиболее распространенным классом алгоритмов наведения являются корреляционно-экстремальные методы, основанные на максимизации корреляционного функционала между измеренным профилем рельефа и соответствующим участком эталонной карты [6,7].

Для фиксированного положения $r = (x, y)$ корреляционный функционал может быть записан в виде

$$C(r) = \sum_{k=1}^N (h_k - \hat{h})(Z^{ref}(x_k + x, y_k + y) - \hat{Z}), \quad (12)$$

где \hat{h} и \hat{Z} – средние значения измеренного и эталонного профилей на рассматриваемом интервале.

Оценка положения ЛА определяется как положение, соответствующее глобальному максимуму функционала:

$$\hat{r} = \arg \max_r C(r).$$

В предположении стационарности и согласованности статистических характеристик рельефа данный функционал является оценкой взаимной корреляции и обеспечивает асимптотически несмещенную оценку положения.

Более строгий подход основан на принципе максимального правдоподобия. При предположении гауссовского характера измерительных ошибок функция правдоподобия имеет вид

$$p(h/r) \propto \exp\left(-\frac{1}{2\sigma_\epsilon^2} \sum_{k=1}^N (h_k - H_k + Z^{ref}(x_k + x, y_k + y))^2\right). \quad (13)$$

Максимизация правдоподобия эквивалентна минимизации квадратичного функционала:

$$\hat{r} = \arg \min_r \sum_{k=1}^N (h_k - H_k + Z^{ref}(x_k + x, y_k + y))^2. \quad (14)$$

Введение артефактных искажений рельефа приводит к систематическому нарушению условий оптимальности классических алгоритмов.

Фактические измерения формируются согласно модели

$$h_k = H_k - Z^{ref}(x_k, y_k) - A(x_k, y_k) + \epsilon_k, \quad (15)$$

где поле $A(x, y)$ отсутствует в эталонной карте.

В этом случае корреляционный функционал принимает вид:

$$C(\mathbf{r}) = C_0(\mathbf{r}) + C_A(\mathbf{r}), \quad (16)$$

где C_0 – полезная корреляционная составляющая, а C_A – добавка, обусловленная артефактами.

Поскольку поле $A(x, y)$ нестационарно и локализовано, вклад C_A может: смещать глобальный максимум корреляции; формировать ложные локальные экстремумы; уменьшать отношение сигнал/шум в корреляционном функционале.

Ошибка оценки положения ЛА определяется как

$$\Delta r = \hat{r} - r^{true}. \quad (17)$$

В условиях отсутствия артефактов дисперсия ошибки определяется корреляционными характеристиками рельефа и уровнем измерительного шума:

$$M \|\Delta r\|^2 \sim \frac{\sigma_{\epsilon}^2}{\sigma_z^2 L^2}, \quad (18)$$

где L – характерная длина корреляции рельефа.

При наличии артефактов к ошибке добавляется смещение, зависящее от амплитуды и пространственного распределения поля $A(x,y)$:

$$M[\Delta r] \neq 0.$$

Ключевые ограничения классических методов наведения заключаются в следующем: жесткая привязка к предположениям стационарности рельефа; высокая чувствительность к локальным искажениям; деградация качества навигации при наличии несоответствий карты и реального рельефа.

Эти ограничения носят принципиальный характер и не могут быть полностью устранены простым увеличением длины окна корреляции или фильтрацией измерений.

4. Методы искусственного интеллекта для наведения летательного аппарата по рельефу местности

В отличие от классических алгоритмов, основанных на явных статистических предположениях о свойствах рельефа, методы искусственного интеллекта рассматривают задачу навигации как задачу восстановления положения летательного аппарата по наблюдаемым данным без явного задания аналитической модели соответствия.

Формально задача сводится к аппроксимации отображения

$$F : h_{k-N+1:k} \rightarrow \hat{r}_k, \quad (19)$$

где $h_{k-N+1:k}$ – фрагмент последовательности измерений радиовысотомера длиной N , а \hat{r}_k – оценка текущего положения ЛА.

Таким образом, задача навигации формулируется как задача регрессии в многомерном пространстве признаков, где рельеф выступает не как объект

явного сопоставления, а как источник устойчивых пространственно-временных паттернов.

Ключевым этапом применения методов машинного обучения является формирование обучающей выборки вида

$$D = \left\{ \left(h^{(i)}, r^{(i)} \right) \right\}_{i=1}^M, \quad (20)$$

где каждому фрагменту измерений соответствует истинное положение ЛА.

В контексте данной работы обучающая выборка формировалась синтетически на основе математической модели рельефа, описанной выше, что позволяет: варьировать статистические характеристики рельефа; контролируемо вводить артефактные искажения; получать репрезентативные данные для обучения и тестирования.

Особое внимание уделялось тому, чтобы артефакты, присутствующие в тестовой выборке, не совпадали с артефактами, использованными при обучении, что позволяет оценивать обобщающую способность моделей.

В зависимости от способа представления входных данных рассматривались различные архитектуры нейронных сетей [8-12].

При представлении фрагмента рельефа в виде двумерного массива высот применялись сверточные нейронные сети (CNN), реализующие отображение

$$\hat{r}_k = f_{CNN}(Z),$$

где Z – локальный участок карты или реконструированный профиль рельефа.

Сверточные слои позволяют автоматически выделять локальные пространственные признаки, устойчивые к малым смещениям и искажениям, что принципиально важно при наличии артефактов.

При использовании одномерных последовательностей измерений высотомера задача решалась с применением рекуррентных нейронных сетей (RNN) и их модификаций (LSTM, GRU):

$$\hat{r}_k = f_{RNN}(h_{k-N+1:k}).$$

Такие модели эффективно учитывают временную структуру измерений и способны выделять характерные изменения профиля рельефа, не привязываясь к точному совпадению абсолютных значений высот.

Для повышения устойчивости к локальным искажениям рассматривались модели с механизмом внимания, в которых вклад отдельных элементов входной последовательности взвешивается адаптивно:

$$\hat{r}_k = f_{Attn}(\mathbf{h}) = \sum_k \alpha_k g(h_k), \quad (21)$$

где коэффициенты α_k определяются в процессе обучения.

Данный механизм позволяет модели снижать влияние участков измерений, искаженных артефактами, и концентрироваться на более информативных фрагментах профиля рельефа.

Обучение нейросетевых моделей осуществлялось путем минимизации функции потерь, отражающей ошибку позиционирования:

$$\mathcal{L} = M \left\{ \left\| \hat{r} - r^{true} \right\| \right\}. \quad (22)$$

Для повышения устойчивости к выбросам использовались робастные модификации квадратичной функции потерь, включая Huber-подобные функции, что особенно важно в условиях наличия артефактных искажений.

Принципиальное отличие методов искусственного интеллекта от классических алгоритмов заключается в отсутствии жесткой привязки к аналитической модели рельефа.

Нейросетевая модель фактически обучается выделять инвариантные признаки формы рельефа, которые: сохраняются при наличии локальных искажений; не требуют строгого совпадения абсолютных высот; могут быть распределены по всему фрагменту траектории.

Результаты численных экспериментов показывают, что при увеличении амплитуды артефактов рост ошибки позиционирования для нейросетевых методов носит более плавный характер по сравнению с классическими корреляционными алгоритмами.

5. Методика сравнительного эксперимента и критерии оценки эффективности

Целью сравнительного эксперимента является количественная оценка эффективности классических алгоритмов наведения и методов искусственного интеллекта в условиях наличия непрогнозируемых артефактных искажений рельефа местности.

Для обеспечения корректности сравнения все рассматриваемые методы функционировали в идентичных условиях: одинаковые реализации базового рельефа; идентичные траектории движения ЛА; одинаковые уровни измерительного шума; совпадающие параметры дискретизации и частоты измерений.

Траектория движения ЛА моделировалась как гладкая квазилинейная функция времени:

$$r(t) = (x(t), y(t)),$$

со скоростью, соответствующей заданному режиму полета.

Пример профиля высот при наличии единичного артефакта приведен на рисунке 3.



Рис. 3. Профиль высот радиовысотомера вдоль траектории полета.

В рамках сравнительного анализа рассматривались классические методы: корреляционно-экстремальный алгоритм; метод максимального правдоподобия и методы искусственного интеллекта: сверточная нейронная сеть; рекуррентная нейронная сеть; модель с механизмом внимания.

Основным критерием эффективности являлась ошибка позиционирования ЛА:

$$e_k = \left\{ \left\| \hat{r} - r^{true} \right\| \right\}.$$

На основе данной величины рассчитывались следующие показатели:

- среднеквадратическая ошибка (RMSE):

$$RMSE = \sqrt{M \left[e_k^2 \right]};$$

- медианная ошибка, устойчивая к выбросам;
- вероятность превышения заданного порога ошибки:

$$P(e_k > e_{thr}).$$

Эти показатели позволяли оценивать как средний уровень точности, так и надежность навигации.

6. Результаты моделирования и сравнительный анализ

В базовом сценарии, при отсутствии артефактных искажений рельефа, все рассмотренные алгоритмы демонстрируют устойчивую работу и корректное определение положения ЛА.

Классические корреляционно-экстремальные методы и методы максимального правдоподобия обеспечивают наименьшую среднеквадратическую ошибку позиционирования при условии согласованности статистических характеристик рельефа и эталонной карты.

Нейросетевые методы в данных условиях не демонстрируют принципиального преимущества по точности, а в отдельных случаях уступают классическим алгоритмам вследствие сглаживающего характера аппроксимации.

Полученные результаты подтверждают, что в идеализированных условиях классические методы остаются практически оптимальными и могут рассматриваться в качестве эталонных.

При введении одиночных локализованных артефактов рельефа наблюдается качественно различное поведение сравниваемых методов.

Для классических корреляционных алгоритмов даже единичный артефакт приводит к искажению корреляционного функционала и смещению его глобального максимума.

Методы искусственного интеллекта демонстрируют более плавную деградацию точности. В большинстве реализаций нейросетевые модели корректно идентифицируют положение ЛА, игнорируя локальное искажение как неинформативный фрагмент входных данных.

Сводный анализ результатов моделирования позволяет сделать следующие обобщающие выводы:

- классические методы обеспечивают максимальную точность в условиях отсутствия искажений;
- методы искусственного интеллекта превосходят классические алгоритмы по устойчивости к непрогнозируемым артефактам;
- при высоком уровне искажений нейросетевые методы обеспечивают более надежную навигацию;
- вычислительные ограничения остаются ключевым фактором при выборе подхода.

Для иллюстрации полученных выводов рассмотрим конкретный числовой пример навигации летательного аппарата по рельефу местности в условиях наличия непрогнозируемых артефактных искажений.

Моделирование проводилось для участка рельефа размером 10×10 км с шагом дискретизации 25 м.

Базовый рельеф моделировался как стационарное случайное поле с гауссовой корреляционной функцией и длиной корреляции $L = 200$ м.

Среднеквадратичное отклонение высот составляло ($\sigma_Z = 15$) м.

Артефактные искажения моделировались в виде локальных возмущений с амплитудой α , отсутствующих в эталонной карте. Рассматривались значения амплитуды: $\alpha \in \{0,1,2,3,4\}$ м.

Траектория ЛА представляла собой прямолинейный полет длиной 6 км. Для каждого сценария проводилось 100 независимых реализаций моделирования.

В таблице 1 приведены значения среднеквадратической ошибки позиционирования (RMSE) для классических алгоритмов и методов искусственного интеллекта.

Таблица 1. Зависимость RMSE от амплитуды артефактных искажений.

Амплитуда артефактов, м	RMSE (классические методы), м	RMSE (методы ИИ), м
0	5	6
1	8	7
2	15	9
3	28	13
4	45	18

При отсутствии артефактных искажений классические алгоритмы демонстрируют наилучшую точность навигации, что согласуется с их теоретической оптимальностью в условиях согласованности модели рельефа и измерений.

Однако уже при амплитуде артефактов ($\alpha = 2$) м наблюдается более чем двукратный рост ошибки для классических методов, тогда как для методов искусственного интеллекта рост ошибки носит существенно более плавный характер.

При максимальной амплитуде искажений ($\alpha = 4$) м ошибка позиционирования классических алгоритмов превышает аналогичный показатель нейросетевых методов более чем в 2,5 раза, что указывает на принципиально различную устойчивость алгоритмов к непрогнозируемым искажениям рельефа.

На рисунке 4 представлена зависимость среднеквадратической ошибки позиционирования от амплитуды артефактных искажений (классические методы – синий график, нейросетевые – оранжевый).




Рис. 4. Влияние амплитуды артефактов на точность наведения ЛА.

На рисунке 5 приведены эмпирические распределения ошибок позиционирования ЛА при использовании классических алгоритмов и методов искусственного интеллекта.

Анализ распределений показал принципиальные различия между классическими алгоритмами и методами искусственного интеллекта.

Для классических алгоритмов распределение ошибок носит выражено немонотонный характер и характеризуется наличием «тяжелого хвоста», связанного с резкими нарушениями корреляционного соответствия между измеренным профилем высот и эталонной картой.

Для методов искусственного интеллекта распределение ошибок близко к гауссовскому и не демонстрирует выраженных выбросов даже при наличии артефактных искажений.




Рис. 5. Эмпирические распределения ошибок позиционирования: синий – классический корреляционно-экстремальный алгоритм; оранжевый – метод искусственного интеллекта; пунктир – порог катастрофического сбоя.

Одним из принципиальных недостатков использования среднеквадратичной ошибки в качестве единственного критерия эффективности решения задач навигации является ее неспособность адекватно отражать риск редких, но критических ошибок позиционирования. В реальных навигационных системах такие ошибки могут приводить к потере устойчивости управления или срыву навигационного решения.

В связи с этим введем интегральный показатель навигационной надежности:

$$P_{над} = P(e < e_{кр}), \quad (23)$$

где e – ошибка позиционирования, $e_{кр}$ – порог катастрофической ошибки.

Количественные результаты представлены в таблице 2. Как видно из таблицы, для классических алгоритмов вероятность катастрофического сбоя

составляет порядка 8 %, что является недопустимо высоким значением для автономных навигационных систем.

Таблица 2. Вероятность катастрофических ошибок позиционирования.

Метод	Вероятность катастрофической ошибки
Классические алгоритмы	0,082
Методы искусственного интеллекта	< 0,001 (не наблюдалась)

В то же время для методов искусственного интеллекта в рамках проведенного эксперимента катастрофические ошибки не были зафиксированы, что указывает на существенно более высокую навигационную устойчивость.

Полученные результаты позволяют сделать важный вывод: даже в случаях, когда средние ошибки классических алгоритмов и методов ИИ сопоставимы, распределения ошибок принципиально различаются.

Классические алгоритмы склонны к редким, но крупным навигационным сбоям, обусловленным структурным несоответствием карты и реального рельефа. Методы искусственного интеллекта, напротив, обеспечивают сглаживание локальных искажений за счет обучения устойчивых признаков рельефа, что резко снижает риск катастрофических ошибок.

На основании проведенных численных экспериментов были получены следующие значения следующих метрик: RMSE – среднеквадратическая ошибка позиционирования; $P(e > e_{кр})$ – вероятность катастрофического сбоя; $P_{над}$ – навигационная надежность; вычислительная сложность алгоритмов в режиме работы на борту ЛА, сведенных в итоговую таблицу 3.

Из таблицы 3 следует, что при наличии непрогнозируемых искажений рельефа решающим фактором становится не минимизация RMSE, а максимизация навигационной надежности $P_{над}$.

Таблица 3 Сравнительная оценка эффективности навигационных алгоритмов¹.

Метод наведения	RMSE, м	$P(e > e_{кр})$	$P_{над}$	Вычислительная сложность	Устойчивость к артефактам
Классические корреляционно-экстремальные алгоритмы	28–45	$\approx 0,08$	$\approx 0,92$	Низкая	Низкая
Методы искусственного интеллекта	13–18	$< 0,001$	$> 0,999$	Средняя / высокая	Высокая
Гибридные методы (перспективно)	10–15	$\ll 0,001$	$\rightarrow 1$	Средняя	Очень высокая

Классические алгоритмы, несмотря на низкую вычислительную сложность и высокую точность в идеальных условиях, демонстрируют пониженную надежность вследствие высокой чувствительности к локальным несоответствиям карты и реального рельефа.

Методы искусственного интеллекта обеспечивают существенно более высокие значения $P_{над}$, что делает их предпочтительными в условиях неопределенности и структурных искажений входных данных.

Гибридные методы, сочетающие аналитическую структуру классических алгоритмов с адаптивными свойствами машинного обучения, представляются наиболее перспективным направлением дальнейших исследований.

Заключение

В работе выполнен сравнительный анализ эффективности наведения летательного аппарата по картам рельефа местности с использованием классических алгоритмов и методов искусственного интеллекта в условиях наличия непрогнозируемых артефактных искажений рельефа.

Предложена математическая модель рельефа, в которой базовая поверхность описывается как стационарное случайное поле, а артефактные

¹ *Примечание:* значения приведены для сценариев с артефактными искажениями средней интенсивности.

искажения моделируются в виде нестационарных локализованных возмущений, отсутствующих в эталонной карте. Показано, что такие искажения принципиально нарушают статистические предположения, лежащие в основе классических корреляционно-экстремальных алгоритмов наведения.

На основе численного моделирования установлено, что в идеализированных условиях при отсутствии искажений классические алгоритмы обеспечивают минимальную среднеквадратическую ошибку позиционирования. Однако при наличии артефактных искажений наблюдается резкое снижение устойчивости навигационных решений и появление редких, но критических навигационных сбоев.

Для адекватной оценки качества навигации введен интегральный показатель навигационной надежности $P_{над} = P(e < e_{кр})$, характеризующий вероятность корректного функционирования навигационного алгоритма при заданном пороге допустимой ошибки. Показано, что данный показатель является более информативным критерием по сравнению с одной лишь среднеквадратической ошибкой.

Результаты моделирования продемонстрировали, что методы искусственного интеллекта обладают существенно более высокой навигационной надежностью по сравнению с классическими алгоритмами в условиях непрогнозируемых артефактных искажений. Это проявляется в отсутствии «тяжелых хвостов» распределений ошибок и резком снижении вероятности катастрофических сбоев.

В то же время установлено, что методы искусственного интеллекта требуют повышенных вычислительных ресурсов и не обладают строгими аналитическими гарантиями оптимальности, характерными для классических алгоритмов. Это ограничивает их самостоятельное применение в бортовых навигационных системах с жесткими вычислительными ограничениями.

На основании проведенного анализа сделан вывод о целесообразности использования гибридных навигационных алгоритмов, сочетающих аналитическую структуру классических методов с адаптивностью и

устойчивостью методов машинного обучения. Такие подходы позволяют одновременно обеспечить приемлемую вычислительную сложность и высокую навигационную надежность.

Полученные результаты могут быть использованы при проектировании автономных систем наведения летательных аппаратов, функционирующих в условиях отсутствия или деградации спутниковой навигации, а также служат основой для дальнейших исследований в области гибридных и адаптивных навигационных систем.

Литература

1. Аранович Г.П., Михайлин Д.А. Управление и наведение самолетов и ракет // Московский авиационный институт. – 2013.
2. Борисов Н.Н., Солодухин М.Ю., Годунов А.И. Бесплатформенная инерциальная навигационная система на базе микромеханических датчиков в составе танковых управляемых ракет // Известия высших учебных заведений. Поволжский регион. Технические науки. – 2024. – №. 3 (71). – с. 55-63.
3. Толстикова А.С., Ушаков А.Е. Противодействие спуфингу и повышение помехоустойчивости аппаратуры потребителя глобальных навигационных спутниковых систем // Интерэкспо Гео-Сибирь. – 2018. – №. 9. – с. 319-327.
4. Белозерова Е.Д. Исследование характеристик алгоритма корреляционно-экстремальной навигации для летательного аппарата // Инженерный журнал: наука и инновации. 2023. №4. с. 1-14.
5. Пономарев А.А., Доросинский Л.Г. Сравнение корреляционно-экстремального и нейросетевого методов наведения летательных аппаратов по цифровым картам рельефа местности // Инженерный вестник Дона. 2025. <http://ivdon.ru/ru/magazine/archive/n11y2025/10531>
6. Скобелев П.О. Корреляционно-экстремальные методы навигации летательных аппаратов. – М.: Радиотехника, 2005.

7. Доросинский Л.Г., Оптимальная обработка радиолокационных изображений, формируемых в РСА, Москва: Издательский дом Академии Естествознания, 2017, 212 с.
8. Тархов Д.А. Нейронные сети. Модели и алгоритмы. – М.: Радиотехника, 2005. – 256 с.
9. Хайкин С. Нейронные сети. – М.: Издательский дом «Вильямс», 2006. – 1103с.
10. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2006. – 452с.
11. Бишоп К.М. Распознавание образов и машинное обучение. Диалектика, 2020. – 962с.
12. Мередит Бруссард. Искусственный интеллект. Пределы возможного. – М.: Альпина, 2020.-258с.

Для цитирования:

Доросинский Л.Г., Пономарев А.А. Сравнительный анализ эффективности наведения летательного аппарата по картам рельефа местности классическими методами и методами искусственного интеллекта при наличии непрогнозируемых артефактных искажений // Журнал радиоэлектроники. – 2026. – № 3. <https://doi.org/10.30898/1684-1719.2026.3.9>