

Сравнение классического и нейросетевого методов наведения летательных аппаратов по цифровым картам рельефа

А.А. Пономарев, Л.Д. Доросинский

Уральский федеральный университет имени первого президента
России Б.Н. Ельцина

Аннотация: В работе проведён сравнительный анализ точности определения координат летательного аппарата (ЛА) классическим корреляционно-экстремальным алгоритмом (КЭА) и методом машинного облучения на основе полносвязной сверточной нейронной сети (*Fully Convolutional Network – FCN*) по картам рельефа местности. В качестве моделей рельефа использованы двумерные коррелированные случайные функции. Показано, что КЭА эффективен при малых объёмах данных, тогда как *FCN* демонстрирует высокую помехоустойчивость после обучения на репрезентативных выборках. Оба метода показали зависимость точности определения координат ЛА от размера эталонной области, количества эталонов, энтропии и коэффициента корреляции случайного рельефа.

Ключевые слова: наведение, Фурье-фильтрация, пространственная корреляция, помехоустойчивость, нейронная сеть, классический алгоритм, рельеф, сравнение, автономность, моделирование.

Введение

Актуальность решаемой задачи обусловлена возрастающими требованиями к автономности и надёжности навигационных систем в условиях возможного противодействия и ограниченной доступности глобальных спутниковых систем позиционирования [1,2]

Традиционные методы наведения, такие как инерциальные навигационные системы (ИНС) и спутниковые системы *GPS*, ГЛОНАСС, обеспечивающие высокую точность в благоприятных условиях [3], обладают существенными недостатками: накоплением ошибок во времени и уязвимостью к радиоэлектронному подавлению [1]. ИНС характеризуются дрейфом показаний, что приводит к прогрессирующему увеличению ошибки позиционирования с течением времени [4].

Спутниковые системы, хотя и обеспечивают высокую точность в благоприятных условиях, критически зависимы от доступности сигналов

спутников и уязвимы для различных видов радиоэлектронного противодействия, включая глушение и спуфинг [5]. Спуфинг – это вид радиоэлектронного противодействия, при котором атакующая сторона генерирует и транслирует поддельные навигационные сигналы, имитирующие сигналы реальных спутников.

Традиционным и широко используемым подходом, приобретающим все большую значимость в современных условиях, является использование карт местности для корректного определения положения летательного аппарата (ЛА). Данный метод основан на сравнении измеренных значений высот с заранее известными эталонными картами рельефа местности [6]. Его принципиальное преимущество заключается в полной автономности – для функционирования не требуется внешних сигналов или источников информации за исключением данных высотомеров.

Разумеется, очевидным ограничением названного метода являются требования к объёму и достоверности карт рельефа, а также способов извлечения информации о координатах ЛА. В данной работе рассматриваются два метода обработки данных рельефа местности: классический корреляционно-экстремальный алгоритм (КЭА) и метод, основанный на использовании полносвязных сверточных нейронных сетей (*Fully Convolutional Network – FCN*). Для формирования двумерных коррелированных полей, используемых в качестве моделей рельефа, применён метод Фурье-фильтрации (поле с некоррелированными отсчётами пропускается через пространственный фильтр с заданной частотной характеристикой таким образом, чтобы сформировать поле с требуемым коэффициентом корреляции).

Целью работы является проведение комплексного сравнительного анализа эффективности КЭА и нейросетевого подхода при различных

условиях эксплуатации, включая различные уровни шума, размеры областей сравнения и характеристик рельефа местности.

Формирование модели рельефа

Для генерации цифровых моделей рельефа (ЦМР) использован метод спектрального преобразования [7,8]. Данная методика позволяет получать двумерные случайные поля с управляемыми статистическими свойствами, в частности, с заданной длиной пространственной корреляции. В основе метода лежит фильтрация исходного некоррелированного случайного поля (белого шума) $\xi(x, y)$ в частотной области с помощью специально подобранного фильтра.

Исходное поле $\xi(x, y)$ представляет собой двумерный белый гауссовский шум с нулевым средним значением и единичной дисперсией. Процедура формирования включает следующие этапы:

1. Задание гауссовой корреляционной функции:

$$K(x, y) = \left(\frac{1}{2\pi\lambda^2} \right) \cdot e^{-\frac{x^2+y^2}{2\lambda^2}},$$

где λ – эффективный интервал корреляции.

2. На втором этапе осуществляется переход из пространственной области в частотную для определения передаточной функции системы. Частотная характеристика (передаточная функция) фильтра $H(\omega_u, \omega_v)$ вычисляется путем применения прямого двумерного преобразования Фурье к корреляционной функции $K(x, y)$, описывающей фильтр в пространственной области:

$$H(\omega_u, \omega_v) = F\{K(x, y)\}.$$

3. На третьем этапе происходит фильтрация в частотной области. Результирующее поле формируется в частотной области через операцию

мультипликативной фильтрации: спектр шума скалярно умножается на комплексную передаточную функцию рельефа $H(\omega_u, \omega_v)$:

$$Z(\omega_u, \omega_v) = \sqrt{H(\omega_u, \omega_v)} \cdot F\{\xi(x, y)\}.$$

4. На последнем этапе происходит возврат в пространственную область. Результирующее изображение $z(x, y)$ синтезируется в пространственной области путем применения обратного двумерного преобразования Фурье к модулированному спектру:

$$z(x, y) = F^{-1}\{Z(\omega_u, \omega_v)\}.$$

В результате формируются цифровые модели рельефа, визуализированные на рис. 1 и 2. Важно отметить, что уменьшение параметра пространственной корреляции λ приводит к возрастанию пространственно-частотного спектра синтезированного поля высот, что проявляется в увеличении доли высокочастотных пространственных гармоник.




Рис. 1. – Синтезированный рельеф с шириной спектра $\lambda = 7$




Рис. 2. – Синтетический рельеф с шириной спектра $\lambda = 3$

Корреляционно-экстримальный алгоритм

Содержание КЭА заключается в формировании оценки степени совпадения или сдвига между двумя сигналами или функциями, что позволяет определить параметры положения ЛА относительно эталонного сигнала. Запишем корреляционную функцию в следующем виде [9]:

$$R(i, j) = \sum_{k=1}^N \sum_{m=1}^M h_u(k, m) \cdot h_z(k - i, m - j),$$

- i, j – дискретные координаты возможного положения летательного аппарата,
- N, M – размеры области сравнения,
- $h_u(k, m)$ – измеренные значения высот,
- $h_z(k-i, m-j)$ – значения эталонной карты.

Определение местоположения ЛА сводится к нахождению координат (i_0, j_0) , при которых функция кросс-корреляции $R(i, j)$ достигает максимума:

$$(i_0, j_0) = \operatorname{argmax} R(i, j).$$

Полносвязная сверточная нейронная сеть

FCN, использованная в работе, представляет собой специализированную архитектуру, предназначенную для обработки пространственных данных, в частности – цифровых моделей рельефа. Основное отличие *FCN* от традиционных сверточных сетей заключается в отсутствии полносвязных слоев, что позволяет сохранять пространственную структуру данных на этапах обработки [10].

Архитектура сети строится по принципу энкодер-декодер, где энкодер выполняет поэтапное извлечение иерархических признаков с постепенным уменьшением пространственного разрешения, а декодер восстанавливает пространственное разрешение для получения карты признаков исходного кода. Подобные архитектуры успешно применяются для обработки пространственных данных, включая задачи анализа земной поверхности и обработки аэрофотоснимков с беспилотных летательных аппаратов [11].

Энкодер состоит из последовательности сверточных слоев с функциями активации *ReLU* и слоев субдискритизации (пулинга):

1. Входной слой: принимает данные высот размерности $N \times M$, где N – количество паттернов, M – количество точек измерения
2. Сверточные блоки:
 - Первый сверточный блок: 32 фильтра размером 3×3
 - Второй сверточный блок: 64 фильтра размером 3×3
 - Третий сверточный блок: 128 фильтра размером 3×3

3. Слои субдискретизации: используется с ядром 2×2 для уменьшения пространственной в 2 раза.

Корреляционный слой вычисляет меру между эталонными и измеренными данными [10].

$$C(i, j) = \sum_{x, y} (R(x, y) - \bar{R})(T(x - i, y - j) - \bar{T}),$$

Декодер выполняет обратную операцию увеличения пространственного разрешения с помощью транспонированной свертки.

Данный подход позволяет сохранять пространственную структуру данных на всех этапах обработки.

Программная реализация

Разработанный программный комплекс представляет собой интегрированную среду для исследования алгоритмов наведения летательных аппаратов по цифровым моделям рельефа. Архитектура системы построена по модульному принципу, обеспечивающему гибкость конфигурации и расширяемость функциональности. Система предоставляет развитые возможности параметризации генерации синтезированного рельефа. Пользователь может задавать геометрические параметры, включая размерность матрицы рельефа в виде количества паттернов и точек измерения, диапазон высот в нормированных значениях.

Реализация нейронной сети была выполнена с использованием фреймворка *PyTorch*, что обусловлено его гибкостью, производительностью и развитыми возможностями для исследовательской деятельности. При разработке архитектуры сети и реализации обучения использовались методики, описанные в [12].

Анализ результатов моделирования

В данном исследовании моделируется процесс автономного определения ЛА. На вход алгоритмов обработки исходных данных: КЭА и *FCN* поочередно подается массив измеренных высот под траекторией полета, и набор эталонных профилей рельефа. Задача алгоритма – найти номер эталонного профиля, который наилучшим образом совпадает с измеренным, тем самым определив текущие координаты ЛА.

Целью моделирования является оценка и сравнение вероятности корректного определения местоположения ЛА для двух методов в зависимости от различных условий: размера эталонной области (N), количества эталонов (M), а также интервала корреляции λ .

На рис. 3-4 показаны результаты экспериментов по влиянию количества эталонов на точность распознавания. С увеличением размера эталонной области вероятность корректного распознавания возрастает для обоих методов. Этот результат объясняется тем, что больший размер эталона содержит больше уникальной пространственной информации, что облегчает задачу сопоставления для обоих алгоритмов. Однако КЭА демонстрирует более высокую эффективность при работе с малыми и средними размерами эталонов ($N = 10, 50$), что объясняется его прямым алгоритмическим подходом к сопоставлению, не требующим обучения.

Эксперименты по исследованию влияния длины пространственной корреляции на точность распознавания представлены на рис. 5-6. При фиксированном размере эталона увеличение количества эталонов приводит к снижению вероятности распознавания. Этот эффект наблюдается для обоих методов, но проявляется по-разному. Для КЭА рост числа эталонов увеличивает пространство поиска и вероятность возникновения ложных корреляционных максимумов. Для *FCN* увеличение количества эталонов при

обучении эквивалентно увеличению сложности задачи классификации. При этом нейросетевой подход показал лучшую устойчивость к росту количества эталонов, что свидетельствует о его лучшей способности к обобщению и фильтрации шумов в условиях большой базы эталонов после адекватного обучения.




Рисунок 3. – Зависимость точности распознавания от длины эталонов для *FCN*




Рисунок 4. – Зависимость точности распознавания от длины эталонов для *КЭА*




Рисунок 5. – Зависимость точности распознавания от количества эталонов для *FCN*




Рисунок 6. – Зависимость точности распознавания от количества эталонов для КЭА

Сравнительный анализ результатов экспериментов, представленных на рис. 7 и 8, позволяет определить зависимость эффективности методов от варьирования параметров N (длина эталона) и M (количество эталонов). При фиксированном $N = 10$ и изменении количества эталонов ($M = 10, 100$) корреляционно-экстремальный алгоритм демонстрирует несколько более высокую точность распознавания по сравнению с *FCN*. В то же время, при анализе влияния размера эталонной области ($N = 10, 100$) наблюдается иная закономерность: в условиях низкого отношения сигнал/шум и при больших

значениях N в сочетании с малыми M преимущество имеет КЭА. Однако с улучшением соотношения сигнал/шум или изменением баланса параметров эффективность FCN возрастает, и данный метод начинает превосходить корреляционно-экстремальный подход.




Рисунок 7. – Зависимость точности распознавания от длины эталонов для КЭА и FCN




Рисунок 8. - Зависимость точности распознавания от количества эталонов для КЭА и FCN

Эксперименты по исследованию влияния длины пространственной корреляции на точность распознавания представлены на рис. 9-10. Уменьшение длины пространственной корреляции приводит к повышению точности распознавания для обоих методов. Этот результат закономерен,

поскольку рельеф с малой длиной корреляции обладает более высокой энтропией и уникальностью фрагментов, что снижает вероятность их ложного совпадения. На рельефах с малой длиной корреляции оба метода работают хорошо, с некоторым преимуществом КЭА на малых выборках. На рельефах с большой длиной корреляции *FCN*, обученная на репрезентативных данных, демонстрирует более высокую помехоустойчивость, так как способна извлекать и использовать более сложные иерархические признаки.




Рисунок 9. – Влияние длины корреляции на точность распознавания для *FCN*




Рисунок 10. – Влияние длины корреляции на точность распознавания для КЭА

Для наглядности сравнительный анализ характеристик двух методов в представлен в таблице 1.

Таблица №1

Сравнительная характеристика КЭА и FCN

Критерий	КЭА	FCN
Требования к данным	Работает с малыми объемами данных	Требует больших наборов данных для обучения
Помехоустойчивость	Средняя, зависит от характеристик рельефа	Высокая после адекватного обучения
Вычислительная сложность	Высокая в реальном времени	Высокая на этапе обучения, ниже на этапе применения
Интерпретируемость	Высокая, прозрачность алгоритма	Низкая, "черный ящик"
Адаптивность	Требует перенастройки параметров	Способна к обобщению после обучения
Устойчивость к росту базы эталонов	Низкая	Высокая

Заключение

В результате проведенного исследования выполнено сравнение двух различных подходов к задаче наведения ЛА по рельефу местности: классического корреляционно-экстремального алгоритма и метода, основанного на использовании полносвязной сверточной нейронной сети.

Проведенный анализ позволяет сделать вывод об отсутствии абсолютного преимущества одного метода над другим. Каждый из подходов демонстрирует свои сильные стороны в различных условиях эксплуатации. КЭА показывает высокую точность и оперативность в условиях, требующих автономности и работы с малыми объемами данных, особенно на сложном, уникальном рельефе. FCN, в свою очередь, демонстрирует более высокую

помехоустойчивость и способность работать с обширными базами эталонных данных на сглаженных рельефах, однако требует этапа ресурсоемкого обучения.

Таким образом, выбор алгоритма должен определяться конкретной оперативной обстановкой, доступными вычислительными ресурсами и характеристиками предполагаемого района полета. Результаты исследования свидетельствуют о перспективности разработки гибридных систем, адаптивно выбирающих или комбинирующих оба метода в реальном времени для достижения максимальной точности и надежности наведения.

Литература

1. Сырокваш С. М., Мехеда В. И. Системы управления и наведения крылатых ракет и противодействия им. // URL: militaryarticle.vibrokatok.by/nauka-i-voennaya-bezopasnost/2008/12107-sistemy-upravleniya-i-navedeniya-krylatyh-raket-i (дата обращения: 3.09.2025).
 2. Аранович Г.П., Михайлин Д.А. Управление и наведение самолетов и ракет. М.: МАИ, 2013. 27 с.
 3. Ширшиков А.С., Павлова Ю.А., Чульмяков И.Ф. Применение систем глобального позиционирования при управлении дорожным движением // Инженерный вестник Дона. 2016. №4. URL: ivdon.ru/ru/magazine/archive/n4y2016/3858
 4. Борисов Н.Н., Солодухин М.Ю., Годунов А.И. Бесплатформенная инерциальная навигационная система на базе микромеханических датчиков в составе танковых управляемых ракет // University proceedings Volga region. Engineering sciences. 2024. №3. С. 55-63.
 5. Толстиков А.С., Ушаков А.Е. Противодействие спуфингу и повышение помехоустойчивости аппаратуры потребителя глобальных навигационных спутниковых систем // ИНТЕРЭКСПО ГЕО-СИБИРЬ. Новосибирск: СГУГиТ, 2018. С. 319-325.
-

6. Белозёрова Е.Д. Исследование характеристик алгоритма корреляционно-экстремальной навигации для летательного аппарата // Инженерный журнал: наука и инновации. 2023. №4. С. 1-14.
7. Борцова М.В. Моделирование земной поверхности с негауссовым распределением высот // Новые информационные технологии в автоматизированных системах. 2012. С. 121-129.
8. Быков В.В. Цифровое моделирование в статистической радиотехнике. М.: Советское радио, 1971. 328 с.
9. Сергиенко А.Б. Цифровая обработка сигналов. СПб.: БХВ-Петербург, 2011. 756 с.
10. Fully Connected Layer vs. Convolutional Layer: Explained // BuiltIn URL: builtin.com/machine-learning/fully-connected-layer (дата обращения: 12.09.2003).
11. Белякова А.Ю., Беляков Ю.Д., Замятин П.С. Решение задачи распознавания объектов и инцидентов на фотоматериалах, полученных с беспилотных летательных аппаратов с использованием методов глубокого обучения // Инженерный вестник Дона. 2021. №5. URL: ivdon.ru/ru/magazine/archive/n5y2021/6985.
12. Эли Стивенс, Лука Антига, Томас Виман PyTorch. Освещающая глубокое обучение. СПб.: Питер, 2022. 572 с.

References

1. Syrokvash S. M., Mekheda V. I. Sistemy upravleniia i navedeniia krylatykh raket i protivodeistviia im [Cruise missile control, guidance and counteraction systems]. URL: militariarticle.vibrokatok.by/nauka-i-voennaia-bezopasnost/2008/12107-sistemy-upravleniia-i-navedeniia-krylatyh-raket-i (data obrashcheniia: 3.09.2025).
2. Aranovich G.P., Mikhailin D.A. Upravlenie i navedenie samoletov i raket [Control and guidance of aircraft and missiles]. М.: МАИ, 2013. 27 p.

3. Shirshikov A.S., Pavlova Iu.A., Chulmiakov I.F. Inzhenernyi vestnik Dona. 2016. №4 URL: ivdon.ru/ru/magazine/archive/n4y2016/3858
4. Borisov N.N., Solodukhin M.Iu., Godunov A.I. University proceedings Volga region. Engineering sciences. 2024. №3. pp. 55-63.
5. Tolstikov A.S., Ushakov A.E. Protivodejstvie spufingu i povы'shenie pomexoustojchivosti apparatury potrebitelya global'ny'x navigacionny'x sputnikovy'x system. INTEREKSPLO GEO-SIBIR. Novosibirsk: SGUGiT, 2018. pp. 319-325.
6. Belozerova E.D. Inzhenernyi zhurnal: nauka i innovatsii. 2023. №4. pp. 1-14.
7. Bortsova M.V. Novye informatsionnye tekhnologii v avtomatizirovannykh sistemakh. 2012. pp. 121-129.
8. Bykov V.V. Tsifrovoe modelirovanie v statisticheskoi radiotekhnike [Digital modeling in statistical radio engineering]. M.: Sovetskoe radio, 1971. 328 p.
9. Sergienko A.B. Tsifrovaia obrabotka signalov [Digital signal processing]. SPb.: BKhV-Peterburg, 2011. 756 p.
10. Fully Connected Layer vs. Convolutional Layer: Explained. BuiltIn URL: builtin.com/machine-learning/fully-connected-layer.
11. Beliakova A.Iu., Beliaikov Iu.D., Zamiatin P.S. Inzhenernyj vestnik Dona. 2021. №5. URL: ivdon.ru/ru/magazine/archive/n5y2021/6985.
12. Eli Stevens, Luka Antiga, Tomas Viman PyTorch. Osveshchaia glubokoe obuchenie [PyTorch. Highlighting Deep Learning]. SPb.: Piter, 2022. 572 p.

Авторы согласны на обработку и хранение персональных данных.

Дата поступления: 17.09.2025

Дата публикации: 28.10.2025