Труды МАИ. 2025. № 141 Trudy MAI. 2025. No. 141. (In Russ.)

Научная статья УДК 629.7 URL: <u>https://trudymai.ru/published.php?ID=184508</u> EDN: https://www.elibrary.ru/RJYEBC

# ПРИМЕНЕНИЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ НАВИГАЦИОННЫХ СИСТЕМ ПОДВИЖНЫХ ОБЪЕКТОВ

### Ассад Аммар<sup>1</sup><sup>∞</sup>, Сергей Анатольевич Сериков<sup>2</sup>

<sup>1,2</sup>Санкт-Петербургский государственный университет аэрокосмического приборостроения. Санкт-Петербург, Российская Федерация <sup>1</sup>ammar.assad225@gmail.com<sup>⊠</sup>

Аннотация. Актуальность работы обусловлена необходимостью повышения точности навигационных систем подвижных объектов в условиях сбоев глобальной системы позиционирования (ГПС). Интегрированные системы, сочетающие ГПС и инерциальную навигационную систему (ИНС), обеспечивают высокоточную навигацион систему систему (ИНС), обеспечивают высокоточную навигацио, однако их точность значительно снижается при нарушениях работы ГПС. В данной статье предложен новый метод ОФК-РНС, который объединяет обобщенный фильтр Калмана (ОФК) и рекуррентную нейронную сеть (РНС) для повышения точности навигационных решений в таких условиях. Новизна исследования заключается в использовании РНС для обработки навигационных данных в режиме сбоев ГПС. Входными данными для РНС служат предыдущие измерения ГПС, а также показания гироскопов и акселерометров ИНС. Выходные данные РНС применяются для корректировки измерений в ОФК, что позволяет улучшить оценку навигационных параметров. Для проверки эффективности предложенного метода проведены эксперименты с использованием двух реальных наборов данных. Сравнение методов ОФК и ОФК-РНС выполнено по ключевым

параметрам: ошибкам ориентации (attitude), горизонтальной погрешности (horizontal error) и скорости ( $V_{ned}$ ). Результаты показали, что метод ОФК-РНС превосходит традиционный ОФК по всем исследуемым показателям. В частности, ОФК-РНС демонстрирует более высокую точность оценки ориентации, снижение горизонтальной погрешности и улучшение оценки скорости. Выводы исследования подтверждают, что предложенный метод ОФК-РНС эффективно повышает точность навигационных систем в условиях сбоев ГПС, что делает его перспективным для применения в системах навигации подвижных объектов.

*Ключевые слова*: глобальная система позиционирования, инерциальная навигационная система, обобщенный фильтр Калмана, рекуррентная нейронная сеть *Для цитирования:* Ассад А., Сериков С.А. Применение рекуррентных нейронных сетей для повышения точности навигационных систем подвижных объектов // Труды МАИ. 2025. № 141. URL: <u>https://trudymai.ru/published.php?ID=184508</u>

#### Original article

# THE APPLICATION OF RECURRENT NEURAL NETWORKS TO IMPROVE THE ACCURACY OF NAVIGATION SYSTEMS OF MOBILE OBJECTS

## Assad Ammar<sup>1⊠</sup>, Sergey A. Serikow<sup>2</sup>

<sup>1.2</sup>Saint-Petersburg State University of Aerospace Instrumentation,
 Saint-Petersburg, Russian Federation
 <sup>1</sup>ammar.assad225@gmail.com<sup>⊠</sup>

*Abstract.* The relevance of this study stems from the critical need to enhance the accuracy of navigation systems for mobile objects, particularly in scenarios where the Global Positioning System (GPS) experiences disruptions. While integrated systems combining GPS and Inertial Navigation Systems (INS) offer high-precision navigation, their performance degrades significantly during GPS outages. To address this challenge, this article introduces a novel EKF-RNN method, which integrates a Extended Kalman Filter

(EKF) with a Recurrent Neural Network (RNN) to improve navigation accuracy under such adverse conditions.

The novelty of the research lies in the innovative use of RNNs to process navigation data during GPS failures. The RNN leverages historical GPS measurements alongside data from INS sensors, such as gyroscopes and accelerometers, to generate corrective outputs. These outputs are then used to refine the measurements within the EKF framework, thereby enhancing the estimation of navigation parameters.

To validate the effectiveness of the proposed method, experiments were conducted using two real-world datasets. A comprehensive comparison was made between the traditional EKF and the EKF-RNN methods across key performance metrics, including orientation errors (attitude), horizontal positioning errors, and velocity ( $V_{ned}$ ). The results demonstrate that the EKF-RNN method outperforms the conventional EKF across all evaluated parameters. Specifically, the EKF-RNN achieves higher accuracy in orientation estimation, significantly reduces horizontal positioning errors, and improves velocity estimation.

The findings showed the effectiveness of the EKF-RNN method in enhancing the robustness and accuracy of navigation systems during GPS disruptions. This makes it a promising solution for deployment in navigation systems for mobile objects, particularly in applications where reliability and precision are paramount.

*Keywords:* Global Positioning System, Inertial Navigation System, Extended Kalman Filter, Recurrent Neural Network

*For citation:* Assad A., Сериков C.A. The application of recurrent neural networks to improve the accuracy of navigation systems of mobile objects. *Trudy MAI*. 2025. No. 141. (In Russ.). URL: <u>https://trudymai.ru/eng/published.php?ID=184508</u>

#### 1- Введение

Навигационные системы движущихся объектов, таких как беспилотные летательные аппараты (БПЛА), включают два алгоритма: алгоритм определения углового положения (ориентации) и навигационный алгоритм. Алгоритм ориентации используется для определения изменения углового положения относительно центра

масс объекта. Для представления ориентации применяются различные методы, включая углы Эйлера, направляющие косинусы, кватернионы и другие. Задача оценки углового положения решается на основе показаний гироскопов в связанном координатном пространстве [1]. Навигационный алгоритм используется лля определения положения центра масс движущегося объекта относительно некоторой опорной системы координат. Для решения задачи навигации применяются данные об ускорениях объекта, измеренные акселерометрами в связанной системе координат. С математической точки зрения, задача навигации сводится решению К дифференциального уравнения, связывающего измеренные ускорения со вторыми производными координат положения объекта. Навигационные уравнения могут быть записаны в любой системе координат, однако наиболее подходящей для этой задачи система Север-Восток-Низ (North-East-Down, NED). Эта является система представляет собой локальную касательную плоскость, определяемую относительно конкретной точки на Земле, заданной широтой, долготой и высотой. Обычно такая система используется в месте измерения или в зоне эксплуатации объекта, например, самолета или дрона. Решение этой задачи реализуется в виде инерциальной навигационной системы (ИНС), которая использует интегрирование данных с инерциальных датчиков, таких как акселерометры и гироскопы, для получения навигационных параметров [2].

В большинстве случаев инерциальная навигационная система (ИНС) сталкивается с рядом недостатков, таких как помехи, неопределенности, шумы и другие источники ошибок. Для дополнения данных ИНС часто используется глобальная система позиционирования (ГПС), которая обеспечивает навигационные параметры для объекта, оснащенного приемником ГПС. Однако и ГПС имеет свои ограничения, включая шумы, подавление сигнала, отсутствие покрытия в некоторых областях, а также низкую скорость передачи данных. Особенно важно учитывать эти недостатки при работе с высокоскоростными объектами, такими как ракеты. Даже небольшая ошибка в определении положения в течение доли секунды может привести к существенному отклонению от цели. Для решения этой проблемы применяется интеграция систем ГПС и ИНС, известная как слабосвязанная архитектура (Loosely

Coupled GPS/INS), которая реализуется с использованием фильтра Калмана. В данной архитектуре информация от ИНС корректируется при наличии сигнала ГПС, а при его отсутствии ИНС продолжает интегрирование до поступления новых данных от ГПС. Однако сбои в работе системы ГПС/ИНС могут возникать в условиях, где сигнал ГПС недоступен или его использование запрещено [3, 4].

Использование методов искусственного интеллекта (ИИ) в области навигации становится все более популярным. Многие исследователи применяют ИИ для повышения точности предоставляемой навигационной информации. В данном исследовании рекуррентная нейронная сеть (РНС) предлагается в качестве нового источника данных. При интеграции систем ГПС/ИНС с использованием фильтра Калмана сигнал ГПС обычно применяется на этапе коррекции. Однако в рассматриваемом подходе РНС будет использоваться на этапе коррекции в случаях, когда сигнал ГПС недоступен. Таким образом, РНС заменяет ГПС в двух сценариях:

- При отключении сигнала ГПС (когда данные от ГПС недоступны в момент, когда они должны быть доступны).
- На каждом шаге выборки, когда данные доступны только от ИНС.

Различные беспилотных транспортных типы средств находят широкое применение в многочисленных областях, включая мониторинг водной среды, географическое картографирование, патрулирование аварийноморское И спасательные операции. В авиационно-ракетной и космической технике беспилотные аэрофотосъемки, аппараты (БПЛА) летательные используются для картографирования, мониторинга сельскохозяйственных угодий, поисковоспасательных операций и доставки грузов. Точность навигационной информации, такой как скорость и положение транспортного средства, играет ключевую роль в обеспечении автономности беспилотных систем для выполнения указанных задач. Предложенный метод ОФК-РНС, описанный в статье, может быть успешно применен для повышения точности навигационных систем БПЛА и других подвижных объектов в авиационно-космической отрасли, особенно в условиях ограниченной доступности сигналов ГПС. Это открывает новые возможности для повышения

надежности и эффективности беспилотных систем в критически важных приложениях [4].

#### 1-1- Обзор литературы

В [6], были использованы различные рекуррентные нейронные сети (РНС), такие как сети Элмана и Джордана, для решения задачи интеграции ГПС/ИНС. Эти обучались с использованием стандартного алгоритма обратного сети ошибки Однако распространения (BPA). данный подход столкнулся С ограничениями, включая низкую скорость сходимости и риск попадания в локальные минимумы, что снижает точность обучения. Для преодоления этих проблем предложена рекуррентная нейронная сеть на основе эволюционного алгоритма (EARNN), которая улучшает точность определения местоположения цели. В работе также проведен анализ интеграции ГПС и ИНС с применением различных нейронных сетей, включая нейронные сети обратного распространения (BPNN), сети Элмана и Джордана. Для обучения этих сетей использовались алгоритмы ВРА, генетический алгоритм и оптимизация роя частиц (PSO). Анализ включал исследование таких рабочих параметров, как средняя абсолютная ошибка (МАЕ), коэффициент детерминации (R<sup>2</sup>), среднеквадратичная ошибка (RMSE), индекс производительности (PI), индекс чувствительности (SI), время обучения сетей и количество эпох. Разработанная РНС применялась для прогнозирования ошибок в определении положения и скорости.

В [7], Авторы предложили интегрированный метод навигации ИНС/ГНСС, основанный на рекуррентной нейронной сети (РНС). Предлагаемый метод использует принцип вычислений ИНС в сочетании с функцией памяти РНС для оценки ошибок, возникающих в ИНС, что обеспечивает непрерывное, надежное и высокоточное навигационное решение. Эффективность предложенного метода впервые была продемонстрирована в среде моделирования ИНС/ГНСС. В дальнейшем был проведен эксперимент на лодке для подтверждения практической работоспособности Результаты экспериментов показывают многообещающие данного подхода. перспективы применения РНС в задачах определения местоположения ЛЛЯ интегрированной навигации ИНС/ГНСС в условиях отсутствия сигнала ГНСС. В

сравнении с другими методами, такими как extreme learning machine (ELM) и обобщенный фильтр Калмана (ОФК), предложенный метод обеспечивает улучшение точности на 30% и 60% соответственно.

В [8] изучается случай сбоев в работе ГПС, которые возникают вследствие воздействия естественных или искусственных факторов, блокирующих сигнал. Для улучшения производительности интеграции ГПС/ИНС во время таких сбоев авторы предложили метод инкрементного регуляризованного обучения LSTM (IncRLSTM). Инкрементное обучение представляет собой парадигму, позволяющую обновлять параметры модели на основе потоковых данных в режиме онлайн, при этом сохраняя знания. Регуляризация, в свою изученные очередь, предотвращает ранее переобучение и улучшает обобщающую способность сети за счет добавления ограничений или штрафных функций к модели. Метод IncRLSTM моделирует сигнал ГПС как задачу многомерной регрессии и корректирует выходные данные ИНС с использованием фильтра Калмана с затухающей памятью. Результаты, полученные на реальных наборах данных, демонстрируют существенное снижение ошибок позиционирования — в среднем на 72% во время сбоев сигнала ГПС. Кроме того, точность и надежность интеграции ГПС/ИНС увеличиваются в среднем на 58% по существующими методами. Преимущество сравнению с IncRLSTM также проявляется в среднем 10%-ном улучшении точности относительно других подходов.

Несмотря на свои преимущества, необходимо учитывать и ограничения использования сетей с долговременной и кратковременной памятью (LSTM) в контексте навигационных систем. Хотя LSTM способны эффективно обрабатывать последовательные данные и помнить важные характеристики, их высокая сложность и необходимость в значительных вычислительных ресурсах могут негативно сказаться на производительности в реальном времени. Более того, наличие долговременной памяти может привести к увеличению задержек в обработке, что критично для навигационных приложений, требующих мгновенной реакции. В этой связи исследование более простых архитектур PHC или новых подходов к интеграции данных навигации может стать важным направлением для дальнейших исследований.

В [6] и [7], рекуррентные нейронные сети (РНС) применялись для прогнозирования ошибок определения местоположения и скорости, после чего эти прогнозы использовались для обновления оценок местоположения и скорости. Однако в обоих случаях для обучения использовались только данные от ГПС. В отличие от предыдущих методов, в подходе РНС используется для оценки измерений с датчиков ГПС, которые затем используются в качестве входных данных на этапе коррекции фильтра Калмана. Для обучения PHC использовались более разнообразные данные, включающие измерения с акселерометров, гироскопов и ГПС.

#### 2- Интеграция систем ГПС-ИНС

#### 2-1- Навигационные системы координат (СК)

Основные системы отсчета. использованные в данном исследовании, включают: инерциальную систему отсчета (*i-CK*), радиально-центральную систему отсчета Земли (*ECEF-CK* или ЕЦЕФ), навигационную систему отсчета (n-CK), систему отсчета тела (*b-CK*) и систему отсчета датчика. Эти системы показаны на 1. Рисунок Между каждыми системами двумя отсчета существует преобразовательная матрица или косинусная матрица, которая используется для представления ориентации одной системы координат относительно другой. Она обозначается как *C*<sup>detination</sup>. В контексте различных систем отсчета, таких как инерциальная система, радиально-центральная система Земли (ECEF) и система оси тела, косинусная матрица может быть сконструирована для описания преобразований между этими системами [9, 10]

Радиально-центральная система отсчета Земли (*ECEF-CK*) жестко фиксирована относительно Земли. Положение вектора  $\vec{r}$  точки в радиально-центральной системе отсчета Земли, обозначается как  $r^e$ .

Навигационная система отсчета (*n-CK*). Навигационная система отсчета (*n-CK*) представляет собой локальную систему координат, используемую для описания навигации транспортного средства. Для корректного определения этой системы необходимо учитывать глобальные (или, исторически, региональные) геодезические

системы отсчета. Обычные геодезические системы отсчета состоят из криволинейных координат (L, l) которые определяют направление нормали (т.е. перпендикуляра) к принятому эллипсоиду вращения (как показано на Рисунок 1). Высота над эллипсоидом h — это расстояние от эллипсоида вдоль нормали к данной точке.



Рисунок 1: i- систем, ECEF система и NED система [9]

Система отсчета тела (*b-CK*). обычно относится к транспортному средству, которое подлежит навигации, и жестко фиксирована относительно него. Начало этой системы отсчета расположено в центре масс транспортного средства, а оси, как правило, определяются вдоль направлений вперед, вправо и вниз соответственно.

Преобразование между координатами ЕСЕГ и координатами LlA: Координаты ЕСЕГ точки  $P_o$  представляют собой нормальные декартовые координаты, состоящие из трех компонентов ( $x_e$ ,  $y_e$ ,  $z_e$ ). В то время как координаты LlA (широта, долгота, высота) являются представлением позиции в геодезической системе отсчета и включают углы широты L, долготы l и высоту h. Геодезические координаты специфичны для заданного вращательно-симметричного эллипсоида с известной полуосью  $R_e$  и сплюснутостью f, где  $f = \frac{Re - Rp}{Re}$ , а Rp — полуось эллипсоида. Связь между декартовыми координатами  $x_e$ ,  $y_e$ ,  $z_e$  и координатами LlA описывается следующими уравнениями (см. [11]):

$$\mathbf{r}^{e} = \begin{bmatrix} x_{e} \\ y_{e} \\ z_{e} \end{bmatrix} = \begin{bmatrix} (N+h)\cos L\cos l \\ (N+h)\cos L\sin l \\ (N(1-e^{2})+h)\sin L \end{bmatrix}$$
(1)

где *N* — это радиус кривизны эллипсоида в нормальном вертикальном плоскости, т.е. плоскости, содержащей нормаль в точке *P<sub>o</sub>* и перпендикулярной меридиану.

$$N = \frac{R_e}{\sqrt{1 - e^2 \sin^2 L}} \tag{2}$$

и  $e^2 = f - f^2$  соответствует квадрату первой эксцентриситета эллипсоида. Радиус кривизны в меридиане *M* определяется следующим образом:

$$M = \frac{R_e (1 - e^2)}{(1 - e^2 \sin^2 L)^{\frac{3}{2}}}$$
(3)

Оба *N* и *M* представляют собой расстояния вдоль нормали к эллипсоиду, проходящей через точку *P<sub>o</sub>*. При этом *N* — это расстояние от эллипсоида до полярной (малой) оси.

#### 2-2- Математическое Моделирование

Скорость движущегося тела представляется следующими уравнениями:

$$\boldsymbol{V}^n = \boldsymbol{C}_e^n \dot{\boldsymbol{r}^e} \tag{4}$$

$$\dot{\boldsymbol{V}}^{n} = -(\boldsymbol{\Omega}_{in}^{n} + \boldsymbol{\Omega}_{ie}^{n}) \cdot \boldsymbol{V}^{n} + \boldsymbol{f}_{n} + \boldsymbol{\overline{g}}_{n}$$

$$\dot{\boldsymbol{P}} = M_{LlA} \cdot \boldsymbol{V}^{n}$$
(6)

Матрица  $M_{LlA}$  будет определена в (Уравнение 11). Матрица  $C_e^n$  редставляет собой матрицу преобразования от системы координат ЕСЕГ к системе координат NED и может быть представлена следующим образом:

$$\boldsymbol{C}_{e}^{n} = \begin{bmatrix} -\sin L \cos l & -\sin L \sin l & \cos L \\ -\sin l & \cos l & 0 \\ -\cos L \cos l & -\sin l \cos L & -\sin L \end{bmatrix}$$
(7)

 $\mathbf{\Omega}_{ie}^{n}$ обозначает Матрица кососимметричную матрицу скорости ECEF инерциальной транспортировки системы относительно системы, Матрица  $\boldsymbol{\Omega}_{in}^{n}$ представленной координат NED. системе обозначает В кососимметричную матрицу скорости транспортировки системы NED относительно инерциальной системы, представленную в системе координат NED (можно записать как  $\Omega_{in}^n = \Omega_{ie}^n + \Omega_{en}^n$ ) [12]. Вектор  $f_n$  представляет собой вектор ускорения в системе NED и выражается как  $f_n = C_b^n f_b$ , где  $f_b$  — это вектор ускорения в системе отсчета тела (которая фиксирована относительно движущегося объекта). Вектор  $\overline{g}_n$  представляет собой локальный вектор гравитации.

Скорость объекта относительно системы ЕСЕF, представленная в координатной системе NED, записывается как  $V^n = [v_N v_E v_D]^T = C_e^n \dot{r}^e$ . Вектор  $P = [L l h]^T$  представляет собой вектор координат местоположения, где L, l и h, - это широта, долгота и высота центра масс объекта. Чтобы выразить компоненты скорости в терминах производных геодезических координат, необходимо вычислить производную по времени вектора  $r^e$  из Уравнения (1):

$$\dot{\mathbf{r}^{e}} = \begin{bmatrix} -\dot{L}(M+h)\sin L\cos l - \dot{l}(N+h)\cos L\sin l + \dot{h}\cos L\cos l \\ -\dot{L}(M+h)\sin L\sin l - \dot{l}(N+h)\cos L\cos l + \dot{h}\cos L\sin l \\ (N(1-e2)+h)\sin L \end{bmatrix}$$
(8)

Это приводит к следующему:

$$\boldsymbol{V} = \begin{bmatrix} \boldsymbol{v}_n \\ \boldsymbol{v}_e \\ \boldsymbol{v}_d \end{bmatrix} = \boldsymbol{V}^n \dot{\boldsymbol{r}}^e = \begin{bmatrix} \dot{L}(M+h) \\ -\dot{l}(N+h)\cos l \\ \dot{h} \end{bmatrix}$$
(9)

$$\begin{bmatrix} v_n \\ v_e \\ v_d \end{bmatrix} = \begin{bmatrix} (M+h) & 0 & 0 \\ 0 & (N+h)\cos l & 0 \\ 0 & 0 & -1 \end{bmatrix} \begin{bmatrix} \dot{L} \\ \dot{l} \\ \dot{h} \end{bmatrix}$$
(10)

Используя Уравнение (10), можно вывести следующее:

$$\begin{bmatrix} \dot{L} \\ \dot{l} \\ \dot{h} \end{bmatrix} = \underbrace{\begin{bmatrix} \frac{1}{(M+h)} & 0 & 0 \\ 0 & \frac{1}{(N+h)\cos l} & 0 \\ 0 & 0 & -1 \end{bmatrix}}_{M_{LIA}} \begin{bmatrix} v_n \\ v_e \\ v_d \end{bmatrix}$$
(11)

Уравнения (5) и (11) показывают расчёт скорости и положения движущегося тела. Параметры ориентации представлены кватернионом, который можно выразить следующим образом:

$$\boldsymbol{q} = [\boldsymbol{e}^{T} = [q_1, q_2, q_3], q_4]^{T}$$
(12)

*q* — это кватернион вращения между системой отсчета N (NED) и системой отсчета В (тело) и определяется как

$$\boldsymbol{q} = \left[\boldsymbol{e}^{T} = \sin\left(\frac{\varphi}{2}\right) \left[\boldsymbol{e}_{x}, \boldsymbol{e}_{y}, \boldsymbol{e}_{z}\right] \, \left|\boldsymbol{q}_{4} = \cos\left(\frac{\varphi}{2}\right)\right]^{T} \tag{13}$$

$$e = sin\left(\frac{\varphi}{2}\right)$$
.  $\hat{e}$  where  $\hat{e} = \left[e_x, e_y, e_z\right]^T$  and  $||e|| = sin\left(\frac{\varphi}{2}\right)$ 

где  $\hat{\boldsymbol{e}}$  — это единичный вектор вращения, а  $\varphi$  угол вращения. Поскольку для описания трехмерного пространства используется четырехмерный вектор, компоненты кватерниона не могут быть независимыми друг от друга. Кватернион удовлетворяет единому ограничению, заданному уравнением  $\boldsymbol{q}^T$ .  $\boldsymbol{q} = 1$ , что аналогично условию, требующему, чтобы  $\hat{\boldsymbol{e}}$  был единичным вектором в параметризации оси/угла Эйлера. Матрица ориентации, которая преобразует систему координат NED в систему координат тела, связана с кватернионом следующим образом

$$C(q) = \Xi^{\mathrm{T}}(q)\Psi(q)$$
  
$$\Xi^{\mathrm{T}}(q) = \begin{bmatrix} q_{4}I_{3\times3} + [\hat{e}\times] \\ -\hat{e}^{T} \end{bmatrix} \quad \Psi(q) = \begin{bmatrix} q_{4}I_{3\times3} - [\hat{e}\times] \\ -\hat{e}^{T} \end{bmatrix}$$
(14)

Где  $[\hat{e} \times]$  — это матрица векторного произведения, которая определяется как в уравнении (16),  $I_{3\times3}$  — это единичная матрица размера (3 × 3). Для малых углов векторная часть кватерниона приблизительно равна половине углов, так что  $\hat{e} = \frac{\alpha}{2}$ , при этом  $q_4 \approx 1$ . где  $\alpha$  это вектор углов крена, тангажа и рыскания. Матрица ориентации может быть тогда аппроксимирована как  $C = I_{3\times3} - [\alpha \times]$  что верно в пределах первого порядка для углов. Кинематическое уравнение для кватерниона ориентации представлено следующим образом [13]:

$$\dot{\boldsymbol{q}} = \boldsymbol{\Omega}(\boldsymbol{\omega}_{nb}^{b})\boldsymbol{q}$$
 where  $\boldsymbol{\Omega}(\boldsymbol{\omega}) = \begin{bmatrix} -[\boldsymbol{\omega} \times] & \boldsymbol{\omega} \\ -\boldsymbol{\omega}^{T} & \boldsymbol{0} \end{bmatrix}$  (15)

Где  $\omega_{nb}^{b} = [\omega_{x} \ \omega_{y} \ \omega_{z}]^{T}$  — это вектор угловой скорости системы координат В относительно системы координат N, выраженный в системе координат В. Матрица, ассоциированная с вектором угловой скорости  $\omega$  обозначаемая как [ $\omega \times$ ] является кососимметричной и определяется как:

$$[\boldsymbol{\omega} \times] = \begin{bmatrix} \mathbf{0} & -\boldsymbol{\omega}_z & \boldsymbol{\omega}_y \\ \boldsymbol{\omega}_z & \mathbf{0} & -\boldsymbol{\omega}_x \\ -\boldsymbol{\omega}_y & \boldsymbol{\omega}_y & \mathbf{0} \end{bmatrix}$$
(16)

#### 2-3- Математическая модель датчиков

Согласно [14], модель измерений акселерометров и гироскопов задается следующим образом

$$\widetilde{\boldsymbol{f}}_{b} = (\boldsymbol{I}_{3\times3} + \boldsymbol{S}_{a})\boldsymbol{f}_{b} + \boldsymbol{b}_{accrrw} + \boldsymbol{b}_{a} + \boldsymbol{W}_{vrw} + \boldsymbol{\eta}_{an}$$
$$\widetilde{\boldsymbol{\omega}}_{b} = (\boldsymbol{I}_{3\times3} + \boldsymbol{S}_{g})\boldsymbol{\omega}_{b} + \boldsymbol{b}_{grrw} + \boldsymbol{b}_{g} + \boldsymbol{W}_{arw} + \boldsymbol{\eta}_{gn} \qquad (17)$$
$$\dot{\boldsymbol{b}}_{a} = \boldsymbol{\eta}_{ab} \qquad \dot{\boldsymbol{b}}_{g} = \boldsymbol{\eta}_{gb}$$

Выходные сигналы  $\tilde{f}_b$  и  $\tilde{\omega}_b$ поступают от сенсоров акселерометров и гироскопов. Истинные значения выходных сигналов обозначаются как  $f_b$  и  $\omega_b$ . Параметры  $b_{accrrw}$  и  $b_{grrw}$  представляют собой случайные блуждания ускорения и скорости соответственно, в то время как  $b_a$  и  $b_g$  обозначают смещения измерений. Параметры  $W_{vrw}$  и  $W_{arw}$  относятся к случайным блужданиям скорости и угла соответственно. Матрицы коэффициентов  $S_a$  и  $S_g$  ключают масштабные факторы и другие коэффициенты, возникающие из ненормальности измерительных осей блоков акселерометров и гироскопов. Процессы  $\eta_{ab}$  и  $\eta_{gb}$  являются белым гауссовским шумом с нулевым средним, и их спектральные плотности задаются как  $\sigma_{ab}^2 I_{3\times3}$  и  $\sigma_{gn}^2 I_{3\times3}$ . В настоящем средним со спектральными плотностями  $\sigma_{an}^2 I_{3\times3}$  и змерений для достижения более четкого анализа и параметризации поведения системы ( $T_s$  — это время выборки.),

$$\widetilde{\boldsymbol{f}}_{b} = (\boldsymbol{I}_{3\times3} + \boldsymbol{S}_{a})\boldsymbol{f}_{b} + \boldsymbol{b}_{a} + \boldsymbol{\eta}_{an} \qquad \dot{\boldsymbol{b}}_{a} = \boldsymbol{\eta}_{ab}$$

$$\widetilde{\boldsymbol{\omega}}_{b} = (\boldsymbol{I}_{3\times3} + \boldsymbol{S}_{g})\boldsymbol{\omega}_{b} + \boldsymbol{b}_{g} + \boldsymbol{\eta}_{gn} \qquad \dot{\boldsymbol{b}}_{g} = \boldsymbol{\eta}_{gb}$$
(18)

#### 2-4- Обобщенный фильтр Калмана

Вектор состояния **x** ів рамках обобщенного фильтра Калмана (ОФК) включает параметры ориентации (кватернионы), координаты объекта (широта, долгота, высота - *LlA*), скорости объекта (*V*), а также смещения гироскопа и акселерометра. Фильтр Калмана состоит из двух основных фаз: фазы прогнозирования (экстраполяции) и фазы коррекции. Фаза прогнозирования использует информацию из предыдущих значений вектора состояния для апреори оценки текущего состояния и может быть записана следующим образом [9]:

$$\boldsymbol{x}_{k+1}^{-} = f(\boldsymbol{t}_{k-1}, \boldsymbol{x}_{k-1}, \boldsymbol{W}_{k-1})$$
(19)

$$x_{k+1}^- = f(x_{k-1}) + G_k W_{k-1}$$

Вектор состояния  $x_k$  определяется следующим образом:

$$\boldsymbol{x}_{k} = \left[\boldsymbol{q}_{k} \boldsymbol{P}_{k} \boldsymbol{V}_{k} \boldsymbol{b}_{g,k} \boldsymbol{b}_{a,k}\right]^{T}$$

Размер вектора состояния составляет (16 × 1).  $W_k$  представляет собой случайный характер эволюции системы (процесса) размером (12 × 1) неизвестной диагональной матрицей ковариации  $Q_k$ , Он состоит из четырёх векторов, каждый из которых содержит три элемента, как показано ниже

 $\eta_{gn}$ : шум гироскопов.  $\eta_{gb}$ : шум смещения гироскопа  $b_g$ .  $\eta_{an}$ : шум акселерометров.  $\eta_{ab}$ : шум смещения акселерометра  $b_a$ .

Основное преимущество использования кватернионов заключается в том, что уравнение кинематики является линейным по отношению к кватерниону и не подвержено сингулярностям. Другим преимуществом кватернионов является то, что последовательные вращения могут осуществляться с помощью умножения кватернионов. В данной работе мы принимаем соглашение, предложенное Лефертсом, Маркли и Шустером, согласно которому кватернионы перемножаются в том же порядке, в каком выполняется умножение матриц ориентации (в отличие от обычной конвенции, установленной Гамильтоном) [16]. Уравнения динамики  $f(\mathbf{x}_{k-1})$  для вектора состояния можно записать следующим образом

$$\boldsymbol{x}_{k+1}^{-} = \begin{bmatrix} \boldsymbol{q}_{k-1} + \frac{T_s}{2} \boldsymbol{\Omega} (\boldsymbol{\omega}_{nb}^b - \boldsymbol{b}_{g,k-1}) \boldsymbol{q}_{k-1} \\ \boldsymbol{p}_{k-1} + T_s \begin{bmatrix} \frac{1}{(M+h)} & 0 & 0 \\ 0 & \frac{1}{(N+h)\cos l_{k-1}} & 0 \\ 0 & 0 & -1 \end{bmatrix} \begin{bmatrix} \boldsymbol{v}_{n,k-1} \\ \boldsymbol{v}_{e,k-1} \\ \boldsymbol{v}_{d,k-1} \end{bmatrix} \\ \boldsymbol{V}_{k-1} + T_s (-(\boldsymbol{\Omega}_{in}^n + \boldsymbol{\Omega}_{ie}^n) \cdot \boldsymbol{V}_{k-1}^n + \boldsymbol{f}_n + \boldsymbol{\overline{g}}_n) \\ T_s \boldsymbol{b}_{g,k-1} \\ T_s \boldsymbol{b}_{g,k-1} \end{bmatrix}$$

Матрица  $G_k$  рассчитывается следующим образом [11-17]:

$$\boldsymbol{G}_{k} = \begin{bmatrix} -(\boldsymbol{I}_{3\times3} - \boldsymbol{S}_{g}) \ \boldsymbol{O}_{3\times9} \\ \boldsymbol{O}_{3\times12} \\ \boldsymbol{O}_{3\times6} - \boldsymbol{C}_{b}^{n}(\boldsymbol{I}_{3\times3} - \boldsymbol{S}_{a}) \ \boldsymbol{O}_{3\times3} \\ \boldsymbol{O}_{3\times3} \ \boldsymbol{I}_{3\times3} \ \boldsymbol{O}_{3\times6} \\ \boldsymbol{O}_{3\times9} \ \boldsymbol{I}_{3\times3} \end{bmatrix}$$
(20)

#### 2-5- Модель измерений

Доступные измерения включают информацию о местоположении и скорости, полученные от ГПС ( $P_{\Gamma\Pi C}, V_{\Gamma\Pi C}$ ). Этап коррекции в фильтре Калмана выполняется, когда появляются новые данные от ГПС. Полный процесс свободно связанной интеграции ИНС/ГПС с использованием фильтра Калмана представлен ниже.



Рисунок 2: Слабо связанная интеграция ГПС/ИНС с использованием (ОФК)

# 2-6- Использование рекуррентной нейронной сети (РНС) с архитектурой layrecnet

Рекуррентная нейронная сеть (РНС) представляет собой класс искусственных нейронных сетей, в которых связи между узлами образуют направленный граф вдоль временной последовательности, выходные данные скрытых сетей повторно поступают на вход скрытой сети, которая обрабатывает новые входные данные скрытых слоев. Это позволяет сети демонстрировать временную динамику поведения. Архитектура layrecnet относится к слоистым рекуррентным нейронным сетям, которые схожи с прямыми нейронными сетями (feedforward), за исключением того, что каждый слой имеет рекуррентную связь с временной задержкой. Такая организация позволяет сети обладать бесконечным динамическим откликом на входные данные временных рядов. На рисунке ниже представлена структура PHC с архитектурой layrecnet. Рекуррентность достигается за счет обратной связи, соединяющей выход скрытого слоя с его входом [18-19].

Этап обучения и тестирования использования РНС показан ниже



Рисунок 3: Этап обучения и тестирования РНС

Функция задержки используется для учета предыдущей информации измерений; количество задержек должно быть проанализировано и протестировано, чтобы определить, сколько задержек требуется для достижения конечной точности оценки местоположения и скорости. Количество выборок на входе РНС обозначается как  $W_i$ . В данном исследовании  $W_i = 4$ . Блок-схема использования Обобщенного фильтра Калмана (ОФК) в сочетании с РНС представлена ниже (Таблица 1)

Таблица 1: Блок-схема ОФК - РНС



	• Иначе							
	• Получить конфигурацию предварительно обученных							
	РНС							
	<ul> <li>Обучение РНС</li> </ul>							
	• Конец							
•	Этап коррекции ОФК							
- Иначе								
•	Если Trained равно единице (1)							
	<ul> <li>Используйте РНС в качестве источника измерения и</li> </ul>							
	получите ( $P_k, V_k$ )							
	<ul> <li>Этап коррекции ОФК</li> </ul>							
•	Иначе							
	<ul> <li>Keep apriori estimation</li> </ul>							
•	Конец							
- Конец								
Конец								

Структура разработанной РНС включает три скрытых слоя, содержащих соответственно 30, 15 и 15 нейронов в каждом слое. Рекуррентность достигается за счет задержки на 2 выборки выходных данных скрытых слоев, которые затем подаются на входные слои. Количество эпох обучения составляет 25 эпох. Выходные данные разработанной РНС имеют размерность 6 (*LlA* и  $V_{ned}$ ), входные данные имеют размерность 13: 3 акселерометра, 3 гироскопа, 3 компоненты скорости, 3 компоненты *LlA*. Входные данные скрытых слоев (включая последние два выхода скрытых слоев: один с задержкой 1, другой с задержкой 2).

**Метод обучения и программное обеспечение**. Рекуррентная нейронная сеть (PHC) была разработана с использованием встроенной функции MATLAB layrecnet. Эта функция позволяет создавать слоистые рекуррентные нейронные сети, оптимальные для задач обработки временных рядов. Архитектура сети была определена с тремя скрытыми слоями с количеством нейронов 30, 15 и 5, соответственно. Основным методом обучения, использованным в данной работе, является алгоритм с контролируемым обучением (trainscg), который реализует стохастический градиентный спуск с изменением размера шага.

Оптимизация гиперпараметров. Поскольку использовалась стандартная функция layrecnet, детали оптимизации гиперпараметров были минимальными. Количество эпох обучения было установлено на уровне 25, и сеть была обучена на заранее подготовленных данных. В будущем могут быть рассмотрены более продвинутые методы оптимизации гиперпараметров для улучшения производительности модели.

Обеспечение устойчивости сети. Для обеспечения устойчивости сети использовались стандартные настройки и параметры, предусмотренные в МАТLAB. Важно отметить, что обучение сети и ее производительность проверялись с помощью валидационного набора данных, целью которого было предотвращение переобучения и обеспечение высокой общей точности сети.

#### 3- Моделирование и результаты

#### 3-1- Набор данных

Для оценки использовались два набора данных, которые содержат всю необходимую информацию: данные акселерометров, гироскопов и ГПС. Частота данных ГПС составляет 10 Гц, а частота данных акселерометров и гироскопов — 100 Гц. Для оценки с использованием первого набора данных в ходе моделирования был добавлен сбой, чтобы проверить, способна ли РНС компенсировать его. Сбой начинается на 125-й секунде и длится 35 секунд. Данный набор данных содержит изменения высоты. Общее время эксперимента составляет 542 секунды.













Ошибка высоты

-4e-01, σ=1e+00 ee = 9e-02, σ=4

600

ОФК: сс

ОФК-Р

Рисунок 4: LlA и скорость (Первый набор данных)



-3 L 0

100 200 300 Время (сек) 400 500 600 -15

-20 L

100 200 300 Время (сек) 400 500 600







Рисунок 5: Ошибка в LlA и скорости (Первый набор данных)

ОФК: среднее=-0.60, σ=3.07 ОФК-РНС: среднее=0.01, σ=0.60 -0.60



Рисунок 6: 2D-путь и 3D-путь (Первый набор данных)

Для второго набора данных сбой произошел на 100-й секунде и длился 60 секунд. Этот набор данных не содержит изменений высоты. Общее время эксперимента составляет 760 секунд. Ниже представлены результаты.



Рисунок 7: LlA и скорость (Второй набор данных)



Рисунок 8: Ошибка в LlA и скорости (Второй набор данных)



Рисунок 9: 2D-путь и 3D-путь (Второй набор данных)



В Таблица 2 показано численное сравнен
--

	Первый набор данных				Второй набор данных			
Параметр	Ошибка	ОФК	ОФК-	Улучшение	Ошибка	ОФК	ОФК-	Улучшение
			РНС	%			PHC	%
Высота (М)	Среднее	0.4	0.09	77.5%	Mean	2	0.3	85
	СКО	1	0.4	60%	STD	20	0.4	98
V <sub>n</sub> (М/сек)	Среднее	0.12	0.05	58.33	Mean	3.66	0.02	99.45
	СКО	0.91	0.48	47.25	STD	12.91	2.29	82.26
V <sub>e</sub> M/сек	Среднее	0.6	0.01	98.33	Mean	0.86	0.16	81.39
	СКО	3.07	0.6	80.45	STD	4.56	1.36	70.17
<i>V<sub>d</sub></i> М/сек	Среднее	0.04	0.03	25	Mean	0.2	0.04	80
	СКО	0.15	0.13	13.33	STD	1.23	0.31	74.79
Горизонтальная	Среднее	20.75	21.15	-	Mean	70.64	19.55	72.32
ошибка (М)	СКО	36.79	26.14	28.94	STD	311.55	54.26	82.55

Таблица 2: Сравнение результатов

Обсуждение результатов приведено в следующем разделе

#### 3-2- Обсуждение

Результаты показали, что использование РНС в качестве источника измерений вместо ГПС в условиях отсутствия сигналов ГПС обеспечивает сходимость интегрированной loosely coupled системы ГПС/ИНС и повышает точность расчета местоположения и скорости движущегося объекта. Использование предыдущей информации от акселерометров и гироскопов вместе с предыдущими данными ГПС в качестве входных данных помогает РНС моделировать, как эти измерения связаны нелинейными уравнениями, чтобы получить текущие измерения ГПС. Рекуррентная

структура предложенной сети позволяет использовать предыдущие входные данные существующих сенсоров. Скрытые слои с задержками (2) эффективно используют информацию из выходов скрытых слоев за несколько предыдущих временных шагов для обучения прогнозированию текущих данных ГПС. Задержки в структуре, реализованные через выходы скрытых слоев, обеспечивают возможность моделировать краткосрочные и долгосрочные зависимости, а также учитывать динамику сенсоров, поскольку измерения инерциальных сенсоров в значительной степени зависят от предыдущих значений.

Кроме того, рекуррентная структура позволяет выявлять нелинейные зависимости между входными данными и целевыми показателями. Эта зависимость является сильно нелинейной из-за шумов, смещений и динамики движения объекта [20]. В качестве метода обучения в РНС использовался алгоритм масштабированного сопряженного градиента, который обеспечивает баланс между скоростью и устойчивостью обучения, а также позволяет эффективно обобщать данные в неизвестных сценариях или условиях, возникающих при отсутствии сигналов ГПС.

#### Заключение

Результаты показали, что разработанный метод превзошел традиционный ОФК по всем ключевым параметрам, при этом показатели улучшения оказались значительными. Сравнение с другими исследованиями в данной области требует применения разработанного метода на одинаковых наборах данных, что не всегда возможно. Однако можно отметить, что в работе [8] среднее улучшение составило 10%, а в исследовании [7] улучшения по скорости (северное и восточное направления) достигли 78% и 71% соответственно. В то же время разработанный метод демонстрирует минимальное улучшение по горизонтальной погрешности на уровне 72,32%, а по скорости (северное и восточное направления) — 99,45% и 81,39% соответственно.

В заключение, интеграция системы глобального позиционирования (ГПС) и инерциальной навигационной системы (ИНС) представляет собой надежное решение для непрерывной и точной навигации. Однако ограничения ГПС, особенно в условиях

сбоев, могут снижать общую точность навигационных систем. Предложенная методика ОФК-РНС эффективно решает эту проблему, объединяя сильные стороны Обобщенного фильтра Калмана и Рекуррентной нейронной сети. Используя последние измерения ГПС вместе с данными инерциальных сенсоров, ОФК-РНС значительно улучшает точность оценки местоположения и скорости в условиях сбоев ГПС. Валидация данного метода с использованием реальных наборов данных продемонстрировала его превосходство над традиционными подходами ОФК, что подчеркивает его потенциал для повышения надежности навигации в критически важных приложениях. Этот подход не только улучшает производительность интегрированных навигационных систем, но и открывает новые перспективы для дальнейших исследований и разработок в области устойчивых навигационных технологий. В ходе работы было упомянуто использование рекуррентных нейронных сетей (РНС) для повышения точности навигационных систем подвижных объектов. Однако одним из перспективных направлений для дальнейших исследований является применение сетей с долговременной и кратковременной памятью (Long Short-Term Memory, LSTM). Несмотря на свои ограничения в контексте быстродействия, LSTM могут предложить уникальные преимущества в обработке последовательной информации, особенно в ситуациях, где важна память о предыдущих состояниях. В дальнейшем исследовании стоит рассмотреть способы оптимизации архитектуры LSTM для достижения более точных и быстрых результатов в системах навигации.

#### Список источников

1. Konovalenko I., Kuznetsova E., Miller A., Miller B., Popov A., Shepelev D., Stepanyan K. New approaches to the integration of navigation systems for autonomous unmanned vehicles (UAV) // Sensors. 2018. No. 18 (9). P. 3010. URL: https://doi.org/10.3390/s18093010

 Bian H., Li A., Ma H., Wang R. Inertial navigation. In Essentials of Navigation: A Guide for Marine Navigation. Singapore: Springer Nature Singapore. 2024. P. 191-222. URL: <u>https://doi.org/10.1007/978-981-99-5636-4</u> Han S., Wang J. Integrated GPS/INS navigation system with dual-rate Kalman Filter // GPS solutions. 2012. No. 16. P. 389-404. URL: <u>https://doi.org/10.1007/s10291-011-0240-X</u>

4. А.Д., Ричняк А.М., Фоминов И.В. Исследование Голяков точности навигационных параметров космического аппарата с адаптивной системой // Труды МАИ. 2022. № 126. URL: автономной навигации https://trudymai.ru/published.php?ID=169009. DOI: 10.34759/trd-2022-126-23

5. Джавадов Н.Г., Агаев Ф.Г., Гусейнов Г.А., Зульфугарлы П.Р. Вопросы оценки выполнимости задач, поставленных перед беспилотными летательными аппаратами // Труды МАИ. 2022. № 127. URL: <u>https://trudymai.ru/published.php?ID=170350</u>. DOI: 10.34759/trd-2022-127-20

6. Malleswaran M., Vaidehi V., Sivasankari N. A novel approach to the integration of GPS and INS using recurrent neural networks with evolutionary optimization techniques // Aerospace Science and Technology. 2014. No. 32 (1). P. 169-179. URL: <a href="https://doi.org/10.1016/j.ast.2013.09.011">https://doi.org/10.1016/j.ast.2013.09.011</a>

 Dai H.F., Bian H.W., Wang R.Y., Ma H. An INS/GNSS integrated navigation in GNSS denied environment using recurrent neural network // Defence technology. 2020. No. 16 (2). P. 334-340. URL: <u>https://doi.org/10.1016/j.dt.2019.08.011</u>

8. Alaeiyan H., Mosavi M.R., Ayatollahi A. Improving the performance of GPS/INS integration during GPS outage with incremental regularized LSTM learning // Alexandria Engineering Journal. 2024. No. 105. P. 137-155. URL: https://doi.org/10.1016/j.aej.2024.06.069

 Assad A., Khalaf W., Chouaib I. Novel adaptive fuzzy extended Kalman filter for attitude estimation in GPS-denied environment // Gyroscopy and Navigation. 2019. No. 10.
 P. 131-146. URL: <u>https://doi.org/10.1134/S2075108719030027</u>

Ермаков П.Г., Гоголев А.А. Программный комплекс алгоритмов автономного определения параметров угловой ориентации беспилотных летательных аппаратов // Труды МАИ. 2022. № 124. URL: <u>https://trudymai.ru/published.php?ID=167100</u>. DOI: <u>10.34759/trd-2022-124-17</u>

11. Jekeli C. Inertial navigation systems with geodetic applications. Walter de Gruyter GmbH & Co KG. 2023.

Xie J., Wang H., Li P., Meng Y. Satellite navigation systems and technologies.
 Singapore: Springer. 2021. URL: <u>https://doi.org/10.1007/978-981-15-4863-5</u>

Quan W., Li J., Gong X., Fang J. INS/CNS/GNSS Integrated Navigation Technology.
 Springer: Berlin, Germany.2015.

14. Al Bitar N., Gavrilov A. A new method for compensating the errors of integrated navigation systems using artificial neural networks // Measurement. 2021. No. 168. P. 108391. DOI: <u>10.1016/j.measurement.2020.108391</u>

15. Ермаков П.Г., Гоголев, А.А. Сравнительный анализ схем комплексирования информации бесплатформенных инерциальных навигационных систем беспилотных летательных аппаратов // Труды МАИ. 2021. No. 117. URL: <u>https://trudymai.ru/published.php?ID=156253</u>. DOI: <u>10.34759/trd-2021-117-11</u>

 Lefferts E.J., Markley F.L., Shuster M.D. Kalman Filtering for Spacecraft Attitude Estimation // Journal of Guidance, Control, and Dynamics. 1982. Vol. 5, No. 5. P. 417–429. URL: <u>https://doi.org/10.2514/3.56190</u>

17. Crassidis J.L. Sigma-point Kalman filtering for integrated GPS and inertial navigation
// IEEE Transactions on Aerospace and Electronic Systems. 2006. No. 42 (2). P. 750-756.
URL: <u>10.1109/TAES.2006.1642588</u>

Pwasong A., Sathasivam S. Forecasting crude oil production using quadratic regression and layer recurrent neural network models // In AIP Conference Proceedings.
 2016. Vol. 1750, No. 1. URL: <u>https://doi.org/10.1063/1.4954514</u>

19. Alabi R.O. Prediction of recurrence and mortality of oral tongue cancer using artificial neural network (A case study of 5 hospitals in Finland and 1 hospital from Sao Paulo, Brazil). 2017.

20. Chow T.W., Fang Y. A recurrent neural-network-based real-time learning control strategy applying to nonlinear systems with unknown dynamics // IEEE transactions on industrial electronics. 1998. No. 45 (1). P. 151-161. DOI: <u>10.1109/41.661316</u>

1. Konovalenko I., Kuznetsova E., Miller A., Miller B., Popov A., Shepelev D., Stepanyan K. New approaches to the integration of navigation systems for autonomous unmanned vehicles (UAV). *Sensors*. 2018. No. 18 (9). P. 3010. URL: https://doi.org/10.3390/s18093010

 Bian H., Li A., Ma H., Wang R. Inertial navigation. In Essentials of Navigation: A Guide for Marine Navigation. Singapore: Springer Nature Singapore. 2024. P. 191-222. URL: <u>https://doi.org/10.1007/978-981-99-5636-4</u>

Han S., Wang J. Integrated GPS/INS navigation system with dual-rate Kalman Filter.
 GPS solutions. 2012. No. 16. P. 389-404. URL: <u>https://doi.org/10.1007/s10291-011-0240-</u>
 X

4. Golyakov A.D., Richnyak A.M., Fominov I.V. Investigation of the accuracy parameters of a spacecraft with an adaptive autonomous navigation system. *Trudy MAI*. 2022. No. 126. (In Russ.). URL: <u>https://trudymai.ru/eng/published.php?ID=169009</u>. DOI: 10.34759/trd-2022-126-23

5. Dzhavadov N.G., Agaev F.G., Guseinov G.A., Zul'fugarly P.R. Issues of assessing the feasibility of tasks assigned to unmanned aerial vehicles. *Trudy MAI*. 2022. No. 127. (In Russ.). URL: <u>https://trudymai.ru/eng/published.php?ID=170350</u>. DOI: <u>10.34759/trd-2022-127-20</u>

6. Malleswaran M., Vaidehi V., Sivasankari N. A novel approach to the integration of GPS and INS using recurrent neural networks with evolutionary optimization techniques. *Aerospace Science and Technology*. 2014. No. 32 (1). P. 169-179. URL: <u>https://doi.org/10.1016/j.ast.2013.09.011</u>

 Dai H.F., Bian H.W., Wang R.Y., Ma H. An INS/GNSS integrated navigation in GNSS denied environment using recurrent neural network. *Defence technology*. 2020. No. 16 (2). P. 334-340. URL: <u>https://doi.org/10.1016/j.dt.2019.08.011</u>

8. Alaeiyan H., Mosavi M.R., Ayatollahi A. Improving the performance of GPS/INS integration during GPS outage with incremental regularized LSTM learning. *Alexandria Engineering Journal*. 2024. No. 105. P. 137-155. URL: https://doi.org/10.1016/j.aej.2024.06.069

 Assad A., Khalaf W., Chouaib I. Novel adaptive fuzzy extended Kalman filter for attitude estimation in GPS-denied environment. *Gyroscopy and Navigation*. 2019. No. 10.
 P. 131-146. URL: https://doi.org/10.1134/S2075108719030027

10. Ermakov P.G., Gogolev A.A. Software complex of algorithms for autonomous determination of the angular orientation parameters of unmanned aerial vehicles. *Trudy MAI*. 2022. No. 124. (In Russ.). URL: <u>https://trudymai.ru/eng/published.php?ID=167100</u>. DOI: <u>10.34759/trd-2022-124-17</u>

11. Jekeli C. *Inertial navigation systems with geodetic applications*. Walter de Gruyter GmbH & Co KG. 2023.

12. Xie J., Wang H., Li P., Meng Y. Satellite navigation systems and technologies. Singapore: Springer. 2021. URL: <u>https://doi.org/10.1007/978-981-15-4863-5</u>

13. Quan W., Li J., Gong X., Fang J. *INS/CNS/GNSS Integrated Navigation Technology*. Springer: Berlin, Germany.2015.

14. Al Bitar N., Gavrilov A. A new method for compensating the errors of integrated navigation systems using artificial neural networks. *Measurement*. 2021. No. 168. P. 108391. DOI: <u>10.1016/j.measurement.2020.108391</u>

15. Ermakov P.G., Gogolev, A.A. Comparative analysis of information integration architectures of strapdown inertial navigation systems for unmanned aerial vehicles. *Trudy MAI*. 2021. No. 117. (In Russ.). URL: <u>https://trudymai.ru/eng/published.php?ID=156253</u>. DOI: <u>10.34759/trd-2021-117-11</u>

16. Lefferts E.J., Markley F.L., Shuster M.D. Kalman Filtering for Spacecraft Attitude Estimation. *Journal of Guidance, Control, and Dynamics*. 1982. Vol. 5, No. 5. P. 417–429. URL: <u>https://doi.org/10.2514/3.56190</u>

17. Crassidis J.L. Sigma-point Kalman filtering for integrated GPS and inertial navigation. *IEEE Transactions on Aerospace and Electronic Systems*. 2006. No. 42 (2). P. 750-756. DOI: <u>10.1109/TAES.2006.1642588</u>

Pwasong A., Sathasivam S. Forecasting crude oil production using quadratic regression and layer recurrent neural network models. *In AIP Conference Proceedings*. 2016. Vol. 1750, No. 1. URL: <u>https://doi.org/10.1063/1.4954514</u>

19. Alabi R.O. *Prediction of recurrence and mortality of oral tongue cancer using artificial neural network* (A case study of 5 hospitals in Finland and 1 hospital from Sao Paulo, Brazil). 2017.

20. Chow T.W., Fang Y. A recurrent neural-network-based real-time learning control strategy applying to nonlinear systems with unknown dynamics. *IEEE transactions on industrial electronics*. 1998. No. 45 (1). P. 151-161. DOI: <u>10.1109/41.661316</u>

Статья поступила в редакцию 30.01.2025

Одобрена после рецензирования 07.02.2025

Принята к публикации 25.04.2025

The article was submitted on 30.01.2025; approved after reviewing on 07.02.2025; accepted for publication on 25.04.2025