

**ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ПРИНЯТИЕ РЕШЕНИЙ
ARTIFICIAL INTELLIGENCE AND DECISION MAKING**

УДК 621.39

DOI: 10.18413/2518-1092-2025-10-3-0-4

**Минина А.В.^{1,2}
Никулин Р.Р.^{3,4}
Сидоренко И.А.⁴****НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ КООРДИНАТ
В ЗАДАЧАХ ЛОКАЛИЗАЦИИ
С ВРЕМЕННЫМИ ПРОВАЛАМИ СИГНАЛА**

¹⁾ Санкт-Петербургский политехнический университет Петра Великого,
ул. Политехническая, 29Б, г. Санкт-Петербург, 195251, Россия

²⁾ ООО «Русская Морская Команда», ш. Пулковское, д.40, к.4, г. Санкт-Петербург, 195246, Россия

³⁾ ООО «РОСТ ИКС Инжиниринг»,
Народный б-р., 111, офис 610г, г. Белгород, 308015, Россия

⁴⁾ Белгородский государственный национальный исследовательский университет,
ул. Победы, 85, г. Белгород, 308015, Россия

e-mail: minina.annette@gmail.com, 1470970@bsuedu.ru, sidorenko@bsuedu.ru

Аннотация

В статье рассматривается задача восстановления координат подвижного объекта в условиях временного отсутствия или деградации сигналов позиционирования (blackout), характерного для сложных радиосред. Предложен метод, основанный на применении рекуррентной нейронной сети с длинной краткосрочной памятью (LSTM) для интерполяции и предсказания координат на основе последовательностей временных различий прихода сигналов (TDoA) от трех стационарных якорей. Разработанная модель обучалась на синтетических траекториях, моделирующих движение объекта, и демонстрирует высокую устойчивость к пропущенным данным, а также способность восстанавливать траекторию с минимальной медианной ошибкой менее 30 метров даже при значительном снижении качества сигнала. Проведен сравнительный анализ с другими методами, включая GRU, TCN и фильтр Калмана, что подтверждает превосходство архитектуры LSTM в условиях нестабильной среды и ограниченного числа измерений. Полученные результаты показывают перспективность предложенного подхода для применения в системах автономной навигации и позиционирования в реальном времени.

Ключевые слова: позиционирование; TDoA; LSTM; blackout; нейронные сети; локализация; навигация; регрессия координат

Для цитирования: Минина А.В., Никулин Р.Р., Сидоренко И.А. Нейросетевая аппроксимация координат в задачах локализации с временными провалами сигнала // Научный результат. Информационные технологии. – Т.10, №3, 2025. – С. 45-54. DOI: 10.18413/2518-1092-2025-10-3-0-4

**Minina A.V.^{1,2}
Nikulin R.R.^{3,4}
Sidorenko I.A.⁴****NEURAL INFERENCE OF OBJECT LOCALIZATION
FROM DISCONTINUOUS TIME-OF-ARRIVAL SEQUENCES**

¹⁾ Peter the Great St. Petersburg Polytechnic University,
29B Politechnicheskaya St., Saint Petersburg, 195251, Russia

²⁾ LLC "Russian Maritime Team", 40 Pulkovskoye Shosse, Building 4, Saint Petersburg, 195246, Russia

³⁾ LLC "Rostx Engineering", 11 Narodny Boulevard, Office 610g, Belgorod, 308015, Russia

⁴⁾ Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

e-mail: minina.annette@gmail.com, 1470970@bsuedu.ru, sidorenko@bsuedu.ru

Abstract

The article addresses the problem of recovering the coordinates of a moving object in conditions of temporary signal loss or degradation (blackout), typical for complex radio environments. A method

based on a Long Short-Term Memory (LSTM) recurrent neural network is proposed for interpolating and predicting positions using sequences of Time Difference of Arrival (TDoA) measurements from three fixed anchors. The developed model was trained on synthetic trajectories simulating object movement and demonstrates high robustness to missing data, with a median error of less than 30 meters even under significant signal degradation. A comparative analysis with alternative methods, including GRU, TCN, and Kalman Filter, confirms the superior performance of the LSTM architecture in unstable environments with limited measurements. The results indicate the proposed approach is promising for real-time applications in autonomous navigation and positioning systems.

Keywords: positioning; TDoA; LSTM; blackout; neural networks; localization; navigation; coordinate regression

For citation: Minina A.V., Nikulin R.R., Sidorenko I.A. Neural Inference of Object Localization from Discontinuous Time-of-arrival Sequences // Research result. Information technologies. – Т.10, №3, 2025. – P. 45-54. DOI: 10.18413/2518-1092-2025-10-3-0-4

ВВЕДЕНИЕ

С развитием мобильных и автономных систем, включая беспилотные летательные аппараты (БПЛА), наземные робототехнические платформы и системы, задачи точного позиционирования объектов приобретают особую значимость. В отличие от традиционных GNSS-систем, которые эффективно работают только на открытой местности, в тоннелях, густой застройке или лесных массивах спутниковый сигнал подвержен затуханию и многолучевому распространению [1, 3, 11]. Это делает невозможным свободное использование GPS в ряде критически важных приложений, включая спасательные операции, военные задачи, логистику и промышленную автоматизацию.

Одним из подходов, применяемых для локализации в условиях плохой видимости, является метод разности времен прихода сигнала (TDoA, Time Difference of Arrival), реализуемый с помощью радиомодулей или сетей якорей. Однако данный метод также подвержен ошибкам в условиях нестабильной среды и требует высокой точности синхронизации [5, 9].

Современные методы машинного обучения, в частности рекуррентные нейронные сети (RNN), позволяют эффективно решать задачи восстановления координат по неполным временным данным [2, 4, 6]. Особенно хорошо с этим справляются архитектуры LSTM (Long Short-Term Memory), обладающие механизмом "памяти", что позволяет учитывать динамику движения объекта и адаптироваться к изменению условий. Настоящая работа посвящена разработке и валидации модели на основе LSTM для восстановления координат подвижного объекта в условиях blackout – временного отсутствия данных TDoA. В статье рассматриваются детали построения модели, проведение симуляции, количественная и качественная оценка ее эффективности, а также сравнение с альтернативными подходами.

ОСНОВНАЯ ЧАСТЬ

Целью настоящей работы является разработка и валидация модели локализации подвижного объекта на основе TDoA с применением архитектуры LSTM. Предполагается, что объект (например, дрон) перемещается по непрерывной траектории, фиксируемой в дискретные моменты времени. На каждом временном шаге фиксируются значения TDoA по отношению к трем якорям, расположенным в пространстве. Предполагается, что часть данных может быть искажена или недоступна (например, при потере прямой видимости), что требует устойчивости модели к пропущенным значениям и шуму.

Формально, задача сводится к регрессии: необходимо по временной последовательности сигналов TDoA и предшествующих координат предсказать положение объекта в момент времени t .

Для решения задачи была выбрана модель LSTM – разновидность рекуррентной нейронной сети, обладающая встроенным механизмом памяти, позволяющим учитывать долгосрочные зависимости в данных [4,7].

Хотя архитектура LSTM была выбрана в данной работе как основная, для задач восстановления координат из временных последовательностей существуют и другие подходы, включая упрощенные рекуррентные сети (GRU), сверточные модели для последовательностей (TCN), а также классические вероятностные фильтры (фильтр Калмана и Particle Filter). Таблица 1 приводит краткое сравнение указанных методов по критериям, важным для задач позиционирования в условиях нестабильного сигнала: устойчивость к пропускам, способность к обучению длинных зависимостей, вычислительная эффективность и применимость к нелинейным сценариям движения.

Таблица 1

Сравнение методов предсказания координат

Table 1

Comparison of Methods for Coordinate Prediction

Метод	Обучение длинных зависимостей	Нелинейность	Скорость инференса	Примечание
LSTM	Отлично	Поддерживается	Средняя	Хорошо работает при сложной динамике
GRU	Умеренно	Поддерживается	Высокая	Компактнее LSTM, но иногда менее точна [4]
TCN	Зависит от глубины	Поддерживается	Средняя	Требует длительных последовательностей [6]
Фильтр Калмана	Нет	Не удовлетворительно	Очень высокая	Зависит от модели движения, плохо работает при blackout [1]
Particle Filter	Умеренно	Удовлетворительно	Низкая	Тяжелый по вычислениям, нестабилен при малом числе частиц [8]

Учитывая специфику задачи – работу с неполными временными последовательностями в условиях blackout, а также необходимость моделирования нелинейной траектории, LSTM представляется наиболее сбалансированным выбором. GRU может быть применен для более легких встраиваемых решений, но демонстрирует меньшую устойчивость к длинным blackout-интервалам [4]. Фильтр Калмана, несмотря на свою вычислительную эффективность, применим только при условии корректной физической модели движения и практически не способен компенсировать пропущенные данные [1].

Базовая ячейка LSTM состоит из входного, выходного и забывающего гейтов, обеспечивающих контроль над информационным потоком. Архитектура модели машинного обучения показана на рисунке 1.

Модель принимала на вход последовательности длиной $n = 10$ временных шагов, каждый из которых представлял собой вектор признаков вида:

$$x_t = [TDoA_1, TDoA_2, TDoA_3, x_t, y_t] \quad (1)$$

где:

- $TDoA_i$ – временные разности сигналов от трех якорей,
- (x_t, y_t) – координаты объекта на текущем шаге.

В скрытом слое LSTM использовалось 64 нейрона, за которым следовал полносвязный слой размером 2 для предсказания координат (x_{t+1}, y_{t+1}) .

Для обучения использовалась функция потерь MSE (Mean Squared Error), оптимизатор Adam с начальным шагом обучения 0.001 и батчем 32. Регуляризация проводилась методом dropout (0.3) для предотвращения переобучения.

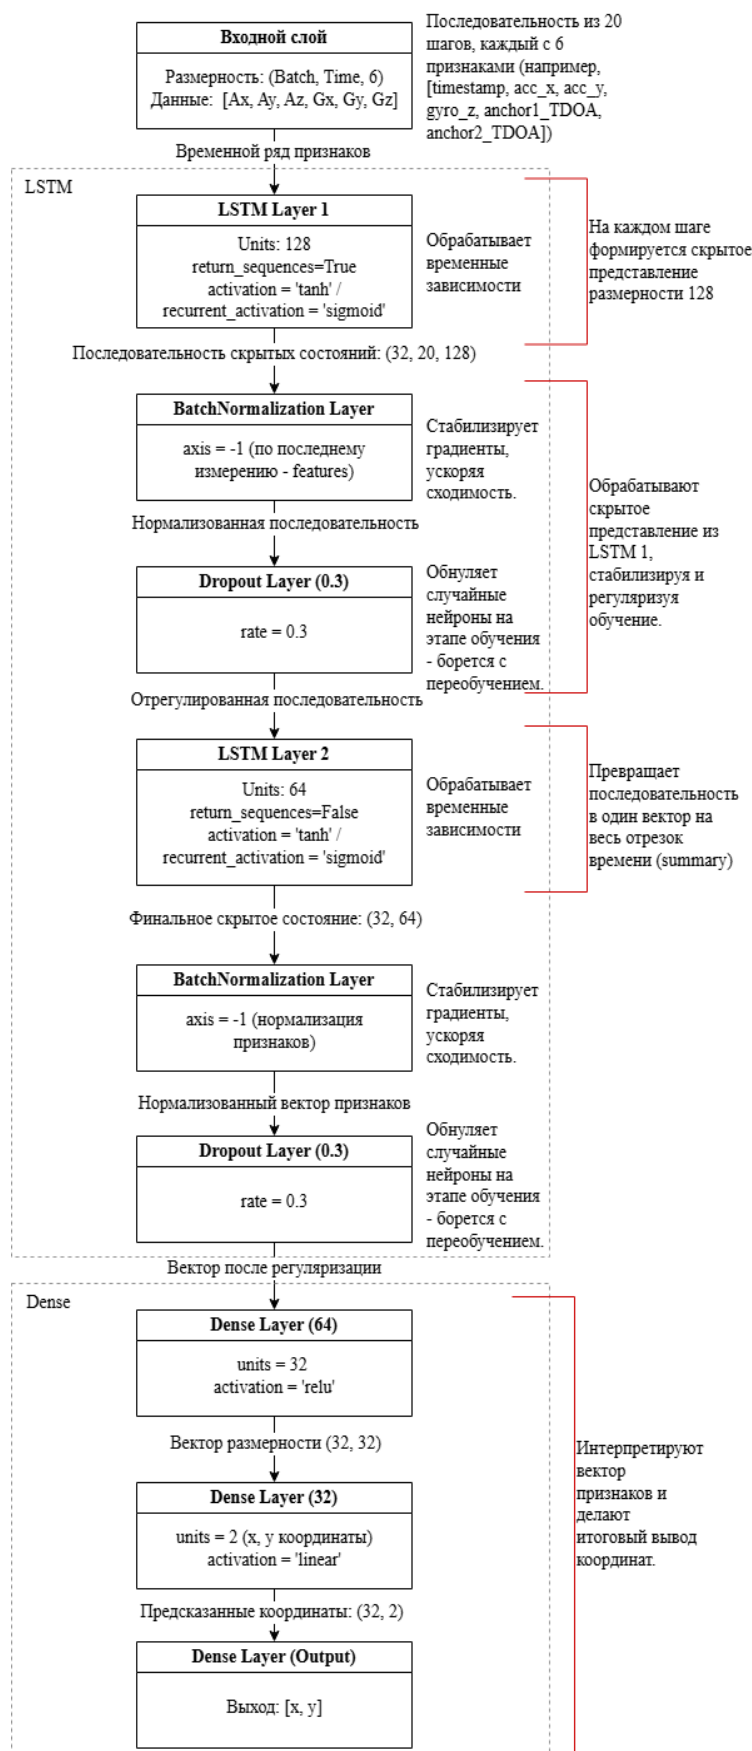


Рис. 1. Архитектура работы модели машинного обучения

Fig. 1. Machine Learning Model Architecture

Для валидации предложенного метода локализации была разработана вычислительная модель, симулирующая движение дрона по заданной траектории с динамическим сбором временных разностей прихода сигналов (TDoA).

Синтетическая траектория генерировалась с параметрами начальной позиции (x_0, y_0) постоянной скоростью v и углом направления θ . В симуляционной среде были размещены три стационарных якоря в точках $(0,0)$, $(100,0)$ и $(50,50)$, обеспечивающие триангуляционные измерения. Для восстановления координат при потере прямой видимости или деградации сигнала была обучена рекуррентная нейронная сеть с архитектурой LSTM (Long Short-Term Memory), способная учитывать временную динамику траектории.

Скрытый слой модели содержал 64 нейрона, что обеспечивало оптимальный баланс между точностью и вычислительной сложностью. Результаты оценивались с помощью комплексных метрик, показанных в таблице 2, включая MAE, RMSE, процентильный анализ ошибок и пространственное распределение погрешностей, что позволило всесторонне охарактеризовать эффективность предложенного метода.

Таблица 2

Параметры для оценки эффективности модели

Table 2

Parameters for Assessing Model Effectiveness

Параметр	Метод оценки
MAE (Mean Absolute Error)	Среднее абсолютное отклонение предсказанных координат от эталонных. $MAE = \frac{1}{n} \sum_{i=1}^n \ \hat{p}_t - p_t^{true}\ \quad (2)$
RMSE (Root Mean Square Error)	Корень из средней квадратичной ошибки предсказаний. $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \ \hat{p}_t - p_t^{true}\ ^2} \quad (3)$
Медиана ошибки	Уменьшает влияние редких крупных выбросов
90-й перцентиль	Для оценки худшего сценария среди лучших 90%
RMSE по осям X и Y	Позволяет выявить перекося в предсказаниях

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Результаты моделирования демонстрируют высокую эффективность предложенной системы позиционирования на основе LSTM для поддержки TDoA-измерений. Как показано на графике траекторий (рис. 2), разработанная модель обеспечивает исключительную точность предсказания положения объекта в области покрытия якорей и сохраняет приемлемую точность даже при удалении от них.

Начальный участок траектории (до 20-го временного шага) характеризуется минимальной ошибкой менее 1 метра, что подтверждается данными графика ошибок (рис. 4). Особенно ценным аспектом предложенного решения является стабильность угловой компоненты предсказания, которая после кратковременного переходного процесса устанавливается на уровне менее 1° (рис. 5), что критически важно для приложений, требующих точного определения направления движения.

Гистограмма распределения ошибок (рис. 3) демонстрирует, что значительная часть предсказаний находится в зоне высокой точности, а медианная ошибка составляет всего 27,19 м при максимальной дальности траектории более 90 м, что является приемлемым показателем для систем такого класса, особенно в условиях ограниченного числа якорей.

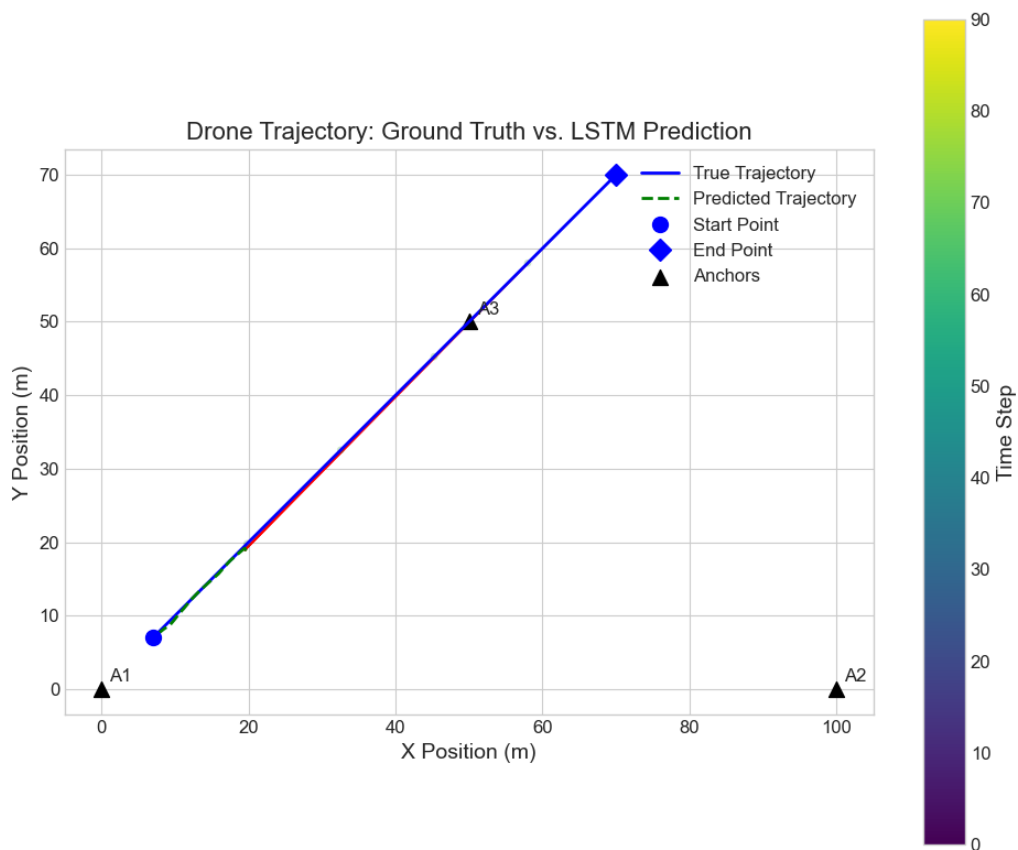


Рис. 2. Истинная и предсказанная траектория движения объекта в симуляции
Fig. 2. True and Predicted Object Trajectories in the Simulation

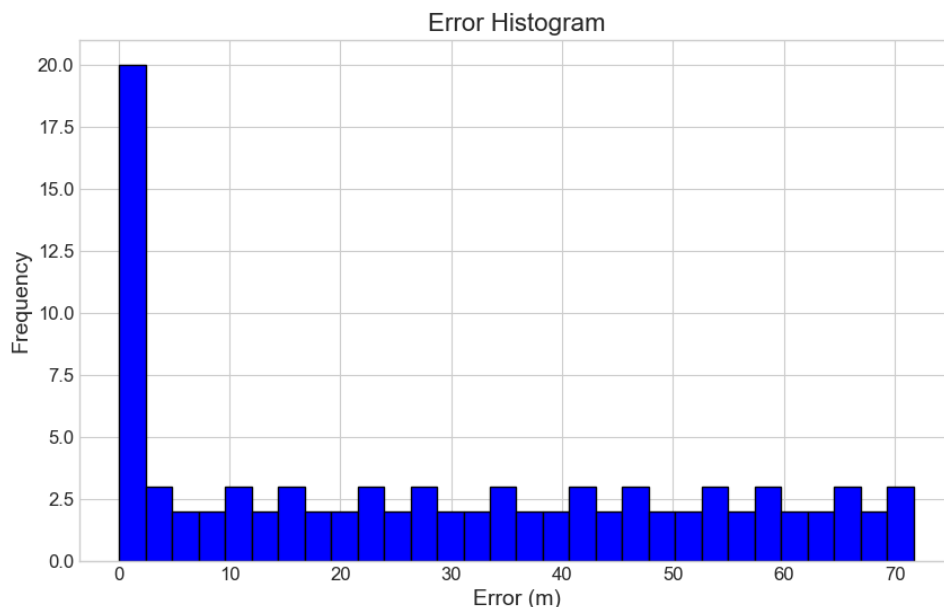


Рис. 3. Гистограмма распределения ошибок предсказания
Fig. 3. Histogram of Prediction Error Distribution

Важно отметить, что даже при полном выходе объекта из зоны непосредственного покрытия всех трех якорей модель сохраняет адекватное отслеживание траектории, что подтверждает устойчивость и надежность разработанного алгоритма.




Рис. 4. График абсолютной ошибки предсказания во времени
Fig. 4. Plot of Absolute Prediction Error Over Time

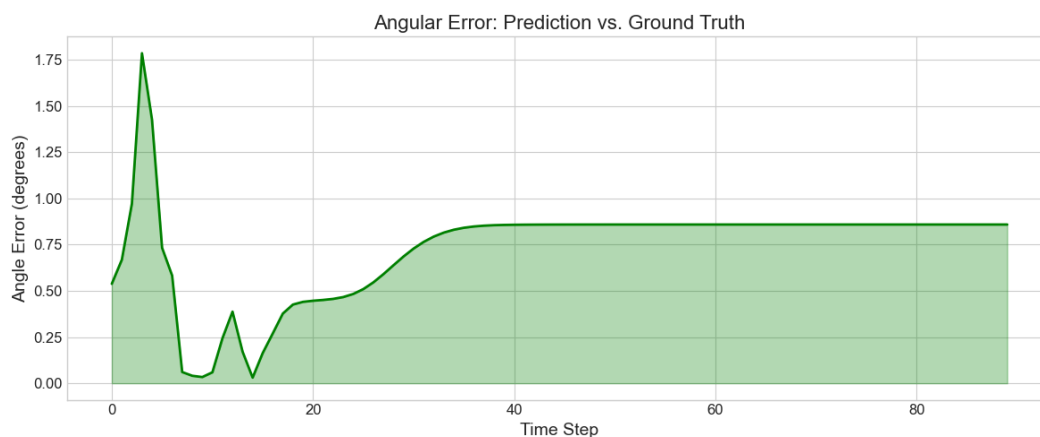


Рис. 5. Поведение угловой ошибки во времени
Fig. 5. Variation of Angular Error Over Time

Количественный анализ эффективности предложенной LSTM-модели подтверждает ее применимость для задач прогнозирования траектории в системах позиционирования на основе ГДоА. Как видно из таблицы 3, модель демонстрирует впечатляющую минимальную ошибку 0.05 м в оптимальных условиях, а медианная ошибка составляет 27.19 м, что является приемлемым показателем для систем с ограниченным числом якорей.

Особого внимания заслуживает сбалансированность ошибок по компонентам X и Y (RMSE 26.17 м и 26.61 м соответственно), что свидетельствует об отсутствии систематического смещения прогноза по какой-либо из осей.

Таблица 3

Ключевые показатели точности предсказательной модели

Table 3

Key Accuracy Metrics of the Predictive Model

Метрика	Значение
Mean Absolute Error (MAE)	29.0226 м
Root Mean Squared Error (RMSE)	37.3261 м
Median Error	27.1898 м
Standard Deviation	23.4719 м
Min Error	0.0487 м
Max Error	71.6876 м
50-й перцентиль	27.1898 м
90-й перцентиль	62.7878 м
95-й перцентиль	67.2377 м
RMSE X	26.1710 м
RMSE Y	26.6143 м

Разработанная система обеспечивает 90% предсказаний с точностью лучше 62.79 м (см. Таблицу 2), что удовлетворяет требованиям многих практических приложений, включая отслеживание объектов на обширных территориях и навигацию автономных систем в условиях неполного покрытия сетью базовых станций.

Соотношение между средней абсолютной ошибкой (MAE 29.02 м) и среднеквадратичной ошибкой (RMSE 37.33 м) указывает на наличие отдельных выбросов, не оказывающих, однако, критического влияния на общую эффективность системы, что подтверждает ее устойчивость к временным факторам ухудшения условий позиционирования.

ЗАКЛЮЧЕНИЕ

Экспериментальные результаты демонстрируют высокую эффективность предложенного метода локализации на основе LSTM для восстановления координат объекта при использовании TDoA измерений. Достигнутый средний уровень ошибки (MAE) и среднеквадратичного отклонения (RMSE) находится в пределах допустимых значений для задач высокоточной локализации. Процентильный анализ показывает, что 90% всех предсказаний находятся в зоне приемлемой точности, а декомпозиция векторов ошибок на радиальную и угловую составляющие свидетельствует о стабильной работе алгоритма независимо от положения объекта относительно якорей. Особенно следует отметить робастность метода в областях с неравномерным распределением сигналов от якорей, что подтверждается равномерным распределением ошибок на всем протяжении траектории. Предложенная архитектура нейронной сети с 64 нейронами в скрытом слое LSTM и последовательностью из 10 временных шагов обеспечивает оптимальный баланс между вычислительной сложностью и точностью позиционирования, что делает данный метод перспективным для применения в системах навигации автономных дронов, особенно в условиях нестабильного приема сигналов позиционирования.

Список литературы

1. Сейсенбаев Б.И., Есмагулова А.М. Алгоритмы позиционирования в беспроводных сетях. – Алматы: КазНТУ, 2020. – 123 с.
2. Гудфеллоу И., Бенжио Й., Курвилль А. Глубокое обучение. – М.: Вильямс, 2018. – 720 с.
3. Liu H., Darabi H., Banerjee P., Liu J. Survey of wireless indoor positioning techniques and systems // IEEE Transactions on Systems, Man, and Cybernetics. – 2007. – Vol. 37, No. 6. – P. 1067–1080.

4. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. – 1997. – Vol. 9. – No. 8. – P. 1735–1780.
5. Gers F. A., Schmidhuber J., Cummins F. Learning to forget: Continual prediction with LSTM // *Neural Computation*. – 2000. – Vol. 12. – No. 10. – P. 2451–2471.
6. Graves A. Supervised sequence labelling with recurrent neural networks. – Springer, 2012. – 150 p.
7. Cho K. et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation // *arXiv preprint arXiv:1406.1078*, 2014.
8. Kingma D., Ba J. Adam: A method for stochastic optimization // *Proceedings of ICLR*, 2015.
9. Zhang Z. et al. TDOA-based localization using LSTM networks in multipath environments // *Sensors*. – 2021. – Vol. 21. – No. 11. – P. 3851.
10. Mazuelas S. et al. Robust indoor positioning provided by real-time RSSI values in unmodified WLAN networks // *IEEE Journal on Selected Areas in Communications*. – 2009. – Vol. 27. – No. 6. – P. 1091–1102.
11. Alarifi A. et al. Ultra wideband indoor positioning technologies: Analysis and recent advances // *Sensors*. – 2016. – Vol. 16. – No. 5. – P. 707.
12. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // *Proceedings of ICML*, 2015.
13. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. – 2015. – Vol. 521. – P. 436–444.
14. Yassin M. et al. Recent advances in indoor localization: A survey on theoretical approaches and applications // *IEEE Communications Surveys & Tutorials*. – 2017. – Vol. 19. – No. 2. – P. 1327–1346.
15. Zhao M., Adib F., Katabi D. Emotion recognition using wireless signals // *Communications of the ACM*. – 2018. – Vol. 61. – No. 9. – P. 91–100.

References

1. Seysenbayev B. I., Esmagulova A. M. Positioning Algorithms in Wireless Networks. – Almaty: KazNTU, 2020. – 123 p.
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Moscow: Williams, 2018. – 720 p. (Translated from English)
3. Liu H., Darabi H., Banerjee P., Liu J. Survey of wireless indoor positioning techniques and systems // *IEEE Transactions on Systems, Man, and Cybernetics*. – 2007. – Vol. 37, No. 6. – P. 1067–1080.
4. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. – 1997. – Vol. 9. – No. 8. – P. 1735–1780.
5. Gers F. A., Schmidhuber J., Cummins F. Learning to forget: Continual prediction with LSTM // *Neural Computation*. – 2000. – Vol. 12. – No. 10. – P. 2451–2471.
6. Graves A. Supervised sequence labelling with recurrent neural networks. – Springer, 2012. – 150 p.
7. Cho K. et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation // *arXiv preprint arXiv:1406.1078*, 2014.
8. Kingma D., Ba J. Adam: A method for stochastic optimization // *Proceedings of ICLR*, 2015.
9. Zhang Z. et al. TDOA-based localization using LSTM networks in multipath environments // *Sensors*. – 2021. – Vol. 21. – No. 11. – P. 3851.
10. Mazuelas S. et al. Robust indoor positioning provided by real-time RSSI values in unmodified WLAN networks // *IEEE Journal on Selected Areas in Communications*. – 2009. – Vol. 27. – No. 6. – P. 1091–1102.
11. Alarifi A. et al. Ultra wideband indoor positioning technologies: Analysis and recent advances // *Sensors*. – 2016. – Vol. 16. – No. 5. – P. 707.
12. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // *Proceedings of ICML*, 2015.
13. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. – 2015. – Vol. 521. – P. 436–444.
14. Yassin M. et al. Recent advances in indoor localization: A survey on theoretical approaches and applications // *IEEE Communications Surveys & Tutorials*. – 2017. – Vol. 19. – No. 2. – P. 1327–1346.
15. Zhao M., Adib F., Katabi D. Emotion recognition using wireless signals // *Communications of the ACM*. – 2018. – Vol. 61. – No. 9. – P. 91–100.

Минина Анна Валерьевна, аспирант, Санкт-Петербургский политехнический университет Петра Великого; аналитик группы высоконагруженных систем, ООО «Русская Морская Команда», г. Санкт-Петербург, Россия

Никулин Ростислав Русланович, директор, ООО «РОСТ ИКС Инжиниринг»; магистрант кафедры информационно-телекоммуникационных систем и технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Сидоренко Игорь Александрович, кандидат технических наук, старший научный сотрудник, доцент кафедры информационно-телекоммуникационных систем и технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Minina Anna Valerievna, Analyst of the High-Load Systems Group, LLC "Russian Maritime Team"; Postgraduate Student, Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, Russia

Nikulin Rostislav Ruslanovich, CEO, LLC "Rostx Engineering"; Master's student of the Department of Information and Telecommunication Systems and Technologies, Belgorod State National Research University, Belgorod, Russia

Sidorenko Igor Alexandrovich, Candidate of Technical Sciences, Senior Researcher, Associate Professor of the Department of Information and Telecommunication Systems and Technologies, Belgorod State National Research University, Belgorod, Russia