

ОПРЕДЕЛЕНИЕ МЕСТОПОЛОЖЕНИЯ АБОНЕНТА С ПОМОЩЬЮ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Ю.С. Лизнева, к.т.н., доцент, Сибирский государственный университет телекоммуникаций и информатики, ktm5r@rambler.ru.

УДК 004.896

Аннотация. Локальные системы позиционирования позволяют абонентам ориентироваться внутри помещений, куда радиосигнал от глобальных навигационных систем проникает с большими искажениями, и это приводит к снижению точности геолокации. Внедрение искусственного интеллекта в системы определения местоположения с целью повышения точности является актуальной задачей, стоящей перед разработчиками. В данной статье рассматриваются различные способы применения алгоритмов машинного обучения к позиционированию мобильного объекта в сети *Wi-Fi* внутри помещений.

Ключевые слова: определение местоположения; локация; *NeuroLab*; машинное обучение; нейронная сеть; *Wi-Fi*; измерение мощности сигнала.

SUBSCRIBER LOCATION USING MACHINE LEARNING ALGORITHMS

Y.S. Lizneva, Candidate of Technical Sciences, Associate Professor, Siberian State University of Telecommunications and Information Science.

Annotation. Local positioning systems allow subscribers to navigate indoors, where the radio signal from global navigation systems coming through obstacles is greatly distorted, which leads to a decrease in the geolocation accuracy. The introduction of artificial intelligence into location systems in order to improve accuracy is an important task the developers face. In this article, various ways of applying machine learning algorithms to positioning a mobile object in the *Wi-Fi* network indoors are discussed.

Keywords: positioning; location; *NeuroLab*; machine learning; machine learning; neural network; *Wi-Fi*; signal strength measurement.

Введение

Перед разработчиками систем определения местоположения в радиосетях стоит множество задач: выбрать технологию, с помощью которой будет построена система позиционирования; выбрать физический параметр, измерение которого позволит вычислить расстояние между передатчиком и приемником сигнала, а на основании этого – координаты целевого объекта; выбрать математические методы для определения расстояния и координат; выбрать аппаратное обеспечение и среду программирования для реализации всех вышеперечисленных этапов и, возможно, некоторые дополнительные компоненты.

Сети *Wi-Fi* (*IEEE* 802.11) представляют собой удобный инструмент для геолокации благодаря своему повсеместному распространению, доступным средствам измерения физических параметров и возможности обеспечить приемлемую точность позиционирования внутри помещений [1].

Определение координат объекта в сети возможно с применением ряда механизмов, таких как латерация; ангуляция; дифференциации пространственных образцов и др. [2, 3]. Большинство этих методов базируется на измерении уровня мощности принятого мобильным устройством сигнала *RSSI* (англ. *Received Signal Strength Indicator*), значение которого в зданиях подвергается влиянию множества факторов: затухание за счет прохождения через перегородки и перекрытия;

многолучевое распространение из-за многократных отражений от этих перегородок и перекрытий; помехи от соседних передатчиков, работающих в том же диапазоне частот; наличие живых препятствий, меняющих свое местонахождение по случайной траектории, и т.п. [4, 5].

Однако, для корректной работы системы определения местоположения в сети *Wi-Fi* требуется выполнение ряда условий: территориально-частотное планирование при размещении точек доступа *AP* (англ. *Access Point*) для обеспечения равномерного радиопокрытия в помещениях; наличие не менее трех точек доступа в пределах видимости приемного устройства с уровнем сигнала не менее -65 дБм; точное знание конфигурации помещений, структуры и материала стен и перекрытий, мебели и пр. [6, 7]. Вышеперечисленное не всегда является доступным для разработчика, поэтому приходится находить другие решения.

Наиболее перспективным выходом из сложной ситуации представляется применение в системе позиционирования глубокого машинного обучения, чему и посвящены дальнейшие разделы данной статьи.

Целью исследования, результаты которого представлены в данной статье, является выбор конфигурации нейронной сети, позволяющей минимизировать ошибку определения местоположения мобильного объекта в существующих на предприятии *Wi-Fi* сетях, изначально не предназначенных для целей геолокации, чтобы обеспечить максимально возможную точность позиционирования.

Понятие машинного обучения

Машинное обучение – раздел искусственного интеллекта, который позволяет выявлять взаимосвязи между объектами и принимать решения без явных команд программиста. Одной из разновидностей машинного обучения является нейросеть (глубокое машинное обучение), представляющая собой последовательность взаимодействующих между собой искусственных нейронов подобно взаимодействию биологических нейронов головного мозга [8, 9]. Рис.1 демонстрирует соотношение понятий искусственного интеллекта, машинного обучения и нейронной сети.



Рисунок 1

Обучение системы происходит на обучающих наборах данных (англ. *training set*), достаточных по объему для выявления закономерностей между входными и выходными данными. Каждый обучающий пример называется обучающим образцом (англ. *training sample*) [10].

Сегодня машинное обучение лежит в основе разнообразных высокотехнологичных процессов и может применяться в таких областях деятельности, как выполнение поисковых запросов, распознавание видео, аудио или

оптических данных, борьба с мошенничеством, осуществление маркетинговых стратегий, прогнозирование дохода (или убытка) компании и многих других. Определение координат мобильного объекта также относится к процессам, которые входят в сферу действия нейронной сети и машинного обучения.

Виды машинного обучения

Существует несколько признаков по которым классифицируют алгоритмы машинного обучения, например [10, 11]:

- наличие контроля (обучение с учителем, обучение без учителя, частичное обучение, обучение с подкреплением);
- возможность постепенного обучения (динамическое и пакетное обучение);
- сравнение или прогнозирование (обучение на основе образцов или моделей).

К наиболее важным алгоритмам машинного обучения относятся:

- *k* ближайших соседей (англ. *k-Nearest Neighbors*). Алгоритм, применяемый в задачах классификации и регрессии, основанный на предположении о том, что расположенные близко друг к другу в пространстве признаков объекты принадлежат одному классу или имеют близкие значения целевой функции;
- линейная регрессия (англ. *Linear Regression*). Это один из видов обучения с учителем, алгоритм которого заключается в нахождении линейной зависимости между входными и выходными наборами данных с минимизацией функции ошибки методом наименьших квадратов;
- логистическая регрессия (англ. *Logistic Regression*). Алгоритм логистической регрессии подсчитывает взвешенные суммы входных признаков плюс смещение, используя сигмоидальную функцию, и выдает результат в виде вероятности принадлежности объекта заданному классу (используется в задачах классификации);
- метод опорных векторов (англ. *Support Vector Machine*). Набор алгоритмов для решения задач регрессии, классификации, а также поиска аномалий. Идея заключается в построении гиперплоскости в пространстве признаков, оптимальным способом разделяющей объекты выборки на классы;
- деревья принятия решений (англ. *Decision Tree*) и случайные леса (англ. *Random Forest*). Деревья решений применяются для анализа больших объемов данных и служат для прогнозирования результатов в зависимости от множества условий. Случайные леса строятся из нескольких независимых решающих деревьев, содержащих различные наборы признаков;
- нейронные сети (англ. *Neural Network*) или глубокое машинное обучение (англ. *Deep Machine Learning*). Подраздел машинного обучения, алгоритмы которого являются многоуровневыми, где каждый уровень производит различную интерпретацию данных и обменивается данными с другими уровнями. С точки зрения машинного обучения нейросеть представляет собой черный ящик со входами, выходами и скрытыми слоями [10].

В дальнейших исследованиях будут применены два вида нейронной сети: сеть прямого распространения и каскадная направленная сеть [12].

Измерение уровня сигнала в экспериментальной сети Wi-Fi

В случае системы определения местоположения обучающим набором являются результаты измерений уровня мощности сигнала в специально размеченных точках помещения, обозначенных измерительными точками (ИТ). Пример экспериментальной зоны приведен на рис. 2.




Рисунок 2

Расстояние между ИТ было выбрано равным 8 м, исходя из предположения, что, приблизившись к искомому объекту (аудитории, буфету, кабинету сотрудника и пр.) на такое расстояние, уже можно визуально определить данный объект.

Согласно [13], метод позиционирования объекта по радиокarte состоит из двух этапов:

- построение радиокарты по результатам измерений;
- определение местоположения объекта по результатам статистической обработки экспериментальных данных.

В каждой измерительной точке были проведены замеры уровней *RSSI* от всех видимых точек доступа. Видимыми *AP* считаем те, от которых приемником мобильного устройства получен сигнал с уровнем мощности не менее -95 дБм.

RSSI в каждой измерительной точке был определен пятью мобильными устройствами, при этом каждым смартфоном выполнялось по 10 измерений. Таким образом, в каждой ИТ фиксировалось 50 результатов измерений мощности. Из дальнейшего анализа исключены измерения, в которых зафиксировано менее трех видимых точек доступа.

Полученные наборы измерений были сведены в таблицу в форме, приемлемой для последующего обучения нейронной сети (*training set*).

Определение местоположения с использованием функций из библиотеки *NeuroLab*

Для осуществления работ была выбрана *NeuroLab* – библиотека базовых алгоритмов нейронных сетей с гибкими сетевыми конфигурациями и алгоритмами обучения для языка *Python*, распространяемая бесплатно по лицензии *GNU Library or Lesser General Public License (LGPL)* [14]. Для упрощения использования библиотеки ее интерфейс аналогичен пакету *Neural Network Toolbox (NNT)* программного обеспечения *MATLAB*. Библиотека основана на пакете *NumPy* языка *Python* с поддержкой многомерных массивов и высокоуровневых математических функций.

Для реализации нейронной сети определения местоположения мобильного объекта были проанализированы следующие алгоритмы машинного обучения в составе библиотеки *NeuroLab*:

- *neurolab.train.train_delta()* – функция, выполняющая обучение по правилу *Delta* методом градиентного спуска в однослойном персептроне;
- *neurolab.train.train_gd()* – функция, реализующая классический алгоритм обратного распространения ошибки, основанный на градиентном спуске;
- *neurolab.train.train_gda()* – функция, применяющая тот же алгоритм, что в предыдущем случае, но с адаптацией коэффициента скорости обучения;
- *neurolab.train.train_gdm()* – функция, реализующая модифицированный алгоритм обратного распространения ошибки с «инерционностью» коррекции весов и смещений;

- `neurolab.train.train_gdx()` – функция, объединяющая в себе особенности алгоритмов представленных функциями `train_gda()` и `train_gdm()`.
- `neurolab.train.train_lm()` – функция, основанная на применении алгоритма оптимизации Левенберга-Марквардта.
- `neurolab.train.train_rprop()` – функция, которая обновляет значения весов и смещения в соответствии с алгоритмом *Resilient backpropagation (Rprop)*;
- `neurolab.train.train_bfgs()` – функция, которая обучает нейронную сеть, используя квазиньютоновский алгоритм Бройдена, Флетчера, Гольдфарба и Шано (*BFGS*);
- `neurolab.train.train_ncg()` – это функция обучения сети, которая обновляет значения весов и смещения по методу масштабированного сопряженного градиента.

Так как соответствие между входами и выходами носит явно выраженный нелинейный характер, то будет использоваться нейронная сеть с нелинейными функциями активации:


- `neurolab.trans.LogSig()` – сигмоидальная логистическая функция;
- `neurolab.trans.TanSig()` – гиперболическая тангенциальная функция.

Из всех рассмотренных выше функций обучения для дальнейшей работы выбраны: `train_lm()`; `train_rprop()`; `train_ncg()` и `train_bfgs()`.

Результаты моделирования

На рис. 3-6 можно видеть результаты определения местоположения объекта на тестовой выборке измерений, которая была сформирована ранее аналогично обучающей выборке.

Рис. 3 содержит значения количества ошибочно определенных координат из тестовой выборки в процентах в нейронной сети прямого распространения для соответствующих алгоритмов машинного обучения и различных значений числа нейронов в скрытом слое – 5, 8, 10. Используется сигмоидальная функция активации.






Рисунок 3

Видно, что наименьший процент ошибок предоставляет нейронная сеть, построенная на функции обучения с алгоритмом Левенберга-Марквардта.

На рис. 4 представлены аналогичные результаты, полученные с помощью каскадной направленной сети с теми же параметрами, что и у ранее рассмотренной нейросети.

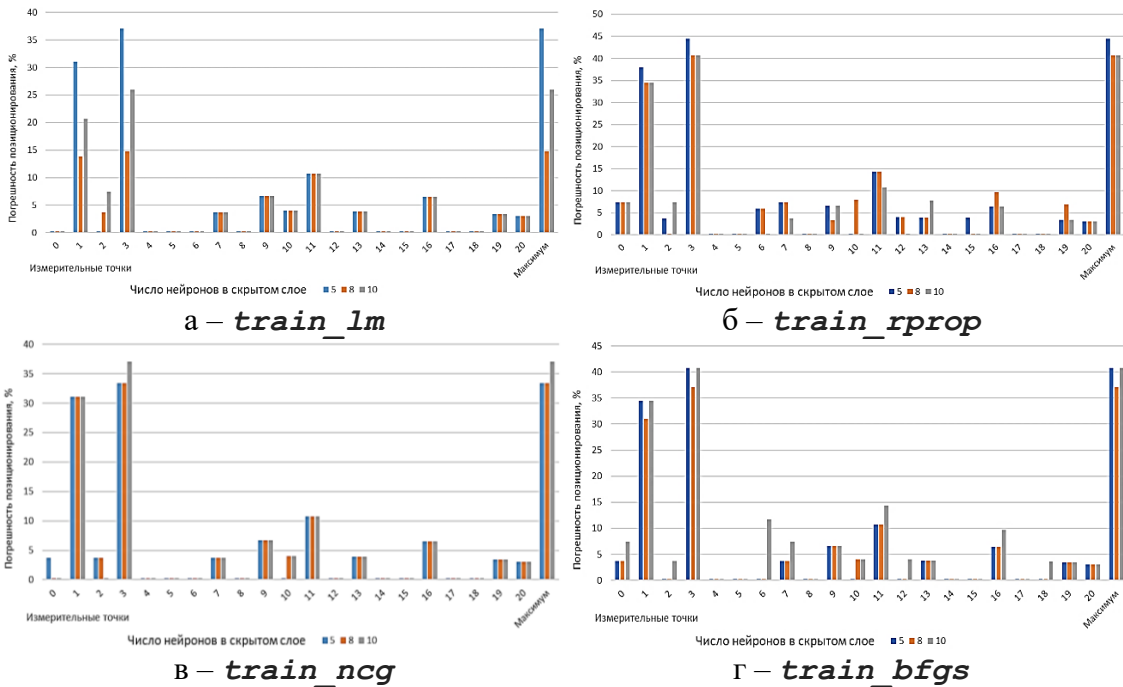



Рисунок 4

Поскольку сеть прямой направленности показала лучшие результаты по сравнению с каскадной направленной, применим ее для дальнейшего анализа, задав другую функцию активации – гиперболический тангенс. Результаты отражены на рис. 5.



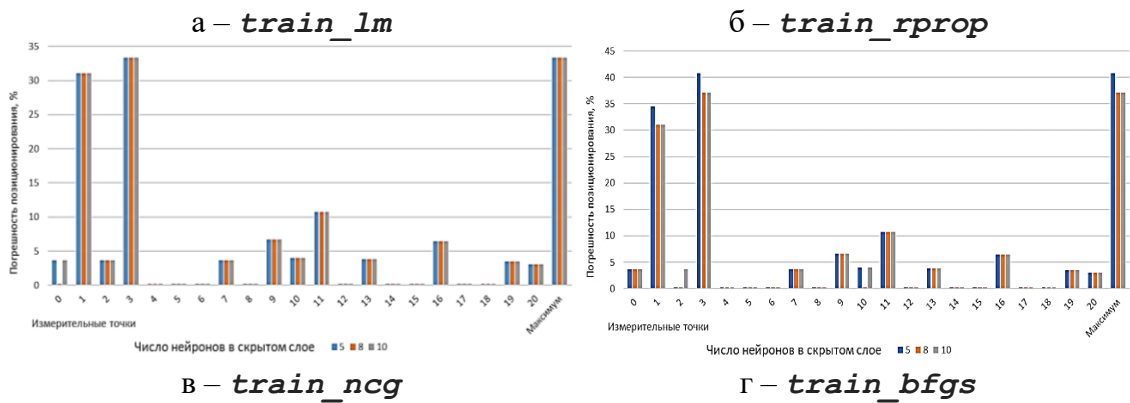


Рисунок 5

Рис. 6 представляет значения корректно определенных координат из тестовой выборки для различных функций машинного обучения и числа нейронов в скрытом слое. Рис. 6а – сеть прямого распространения с сигмоидальной функцией активации; 6б – каскадная направленная сеть с сигмоидальной функцией активации и 6в – сеть прямого распространения с гиперболически тангенциальной функцией активации.




Рисунок 6

Из рис. 6 можно сделать вывод, что наилучшие показатели продемонстрировал алгоритм *train_lm* в сети с 10 нейронами в скрытом слое с тангенциальной функцией активации как в отношении максимальной погрешности вычислений, так и с точки зрения количества точно определенных значений.

На рис. 7 можно видеть фрагмент экспериментальной зоны с размеченными разными цветами результатами позиционирования: зеленый – точно; желтый – погрешность менее 8 м; красный – погрешность в пределах 16 м.




Рисунок 7

Заключение

Проведенный в работе сравнительный анализ показал, что в условиях сложной радиообстановки внутри помещения нейронная сеть прямой передачи, основанная на алгоритме обучения Левенберга-Марквардта с применением

гиперболической тангенциальной функции активации и десятью нейронами в скрытом слое, показала наилучший результат среди подобных сетей в системе определения местоположения. Ошибка позиционирования объекта с применением данного алгоритма глубокого машинного обучения ни в одной точке помещения не превышает 16 м, при этом количество некорректно вычисленных координат не превышает 14% в наихудшем случае, в то время как другие алгоритмы показали значение 26%.

Независимо от приведенных в статье результатов, продолжаются работы по оптимизации методов определения местоположения движущегося объекта с целью уменьшения погрешности позиционирования и достижения не менее чем 90-процентного попадания в цель.

Благодарности

Исследования проводились в рамках государственного задания № 071-03-2024-008 «Прикладные научные исследования в области создания и развития перспективных средств и систем связи, устройств интеллектуальной электроники, инструментария высокопроизводительной обработки и защиты информации с внедрением результатов в образовательный процесс подготовки кадров для цифровой экономики (этап 1)» от 19.01.2024.

Литература

1. Jekabsons G., Kairish V., Zuravlyov V., An Analysis of Wi-Fi Based Indoor Positioning Accuracy // Scientific Journal of Riga Technical University, 2011. – pp. 131-137.
2. Кокорева Е.В. О системах локального позиционирования кратко и по существу // Современные проблемы телекоммуникаций : материалы международной научно-технической конференции // Сибирский государственный университет телекоммуникаций и информатики. Новосибирск, 2021. – С. 551-556.
3. Лизнева Ю.С., Кокорева Е.В., Костюкович А.Е. Прогнозирование местоположения мобильного абонента в сети Wi-Fi // Вестник СибГУТИ, 2022. – № 3. – С. 101-111.
4. Bensky A. Wireless Positioning Technologies and Applications, 2nd Edition. – Boston, London: Artech House, 2016. – 424 p.
5. Kyuder T. RSSI-based method in Indoor Asset Tracking: Benefits, Drawbacks and Comparison with AoA [Электронный ресурс]. – URL: <https://navigine.com/blog/rssi-based-method-in-indoor-asset-tracking/> (дата обращения – сентябрь 2024 г.).
6. Костюкович А.Е., Кокорева Е.В., Якушев И.Ю., Зубкова Н.О., Дошинский И.В. Исследование и разработка системы определения мест // Отчет о НИР. – № 084-00003-19-00 от 27.12.2018 (Федеральное агентство связи), 2019. – 109 с.
7. Kokoreva E., Shurygina K., Bragin A. Impact of Wi-Fi network coverage planning on the logistics objects' location accuracy // E3s web of conferences : XV International Scientific Conference on Precision Agriculture and Agricultural Machinery Industry «State and Prospects for the Development of Agribusiness – INTERAGROMASH 2022», Rostov-on-Don, 2022. – Vol. 363. – pp. 1-10.
8. Chollet F. Deep Learning with Python : 2nd Edition. – Shelter Island, NY : Manning Publications Co., 2021. – 504 p.
9. Pattanayak S. Pro Deep Learning with TensorFlow 2.0: A Mathematical Approach to Advanced Artificial Intelligence in Python. – Bangalore, Karnataka : Apress Media LLC, 2023. – 667 p.
10. Жером О. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow, 2-е изд. : Пер с англ. – СПб. : ООО «Диалектика», 2020. – 1040 с.

11. Зубарев В. Машинное обучение для людей [Электронный ресурс]. – URL : <https://eldf.ru/machine-learning-base-article> (дата обращения – октябрь 2024 г.).
12. Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и приложения: учеб. пособие. – Казань: Изд-во Казан. ун-та, 2018. – 121 с.
13. Кучин И.Ю., Иксанов Ш.Ш., Рождественский С.К., Коряков А.Н. Разработка системы позиционирования и контроля объектов с помощью беспроводной технологии Wi-Fi // Системы анализа и обработки данных, 2015. – № 3 (60). – С. 130-146.
14. NeuroLab's 0.3.5 documentation [Электронный ресурс]. – URL: <https://pythonhosted.org/neurolab/index.html> (дата обращения – октябрь 2024 г.).