

УДК 004.9

DOI: [10.26102/2310-6018/2025.51.4.014](https://doi.org/10.26102/2310-6018/2025.51.4.014)

Применение методов машинного обучения для классификации зданий и сооружений по функциональному назначению на основе геопространственной информации

А.М. Смолев¹, О.К. Головнин²✉

¹Самарский национальный исследовательский университет имени академика С.П. Королева, Самара, Российская Федерация

²Самарский государственный медицинский университет, Самара, Российская Федерация

Резюме. Статья посвящена исследованию возможности применения методов машинного обучения для решения задачи классификации зданий и сооружений по их функциональному назначению на основе геопространственных данных. Обозначена проблема определения типа зданий и сооружений в реальных условиях с ограниченными исходными данными. Рассмотрены существующие подходы к решению задачи классификации объектов. Создан новый набор данных, включающий около 66 тыс. объектов различной функциональной принадлежности на территории Российской Федерации. Рассмотрены этапы подготовки данных, выделения признаков и процесс нормализации геометрий объектов на карте. Проведены эксперименты с использованием методов машинного обучения, в том числе методов искусственного интеллекта. Результаты исследований показывают, что максимальная точность классификации с использованием графовой нейронной сети составляет 83 %, что делает предложенный подход перспективным для практических применений в геоинформационных системах. Выявлен ряд факторов, снижающих точность классификации, связанных с недостаточностью геометрической информации и особенностями форм зданий определенных категорий в условиях реальной застройки. Приведены рекомендации по повышению точности классификации путем оптимизации архитектуры нейронных сетей и расширения набора признаков. Таким образом, статья предлагает эффективный подход к автоматизированной классификации зданий и сооружений, основанный на анализе геометрических свойств и окружающей среды, который может существенно облегчить процессы проектирования и управления инфраструктурой.

Ключевые слова: классификация, машинное обучение, координатное преобразование, геометрические характеристики, геоинформационная система, метод случайного леса, графовая нейронная сеть, ГИС.

Для цитирования: Смолев А.М., Головнин О.К. Применение методов машинного обучения для классификации зданий и сооружений по функциональному назначению на основе геопространственной информации. *Моделирование, оптимизация и информационные технологии*. 2025;13(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=2057> DOI: 10.26102/2310-6018/2025.51.4.014

Machine learning classification of buildings by function using geospatial data

A.M. Smolev¹, O.K. Golovnin²✉

¹Samara National Research University, Samara, the Russian Federation

²Samara State Medical University, Samara, the Russian Federation

Abstract. The article is devoted to the study of the possibility of using machine learning methods to solve the problem of classifying buildings and structures by their functional purpose based on geospatial

data. The problem of determining the buildings and structure types in real conditions with limited initial data is outlined. Existing approaches to solving the problem of classifying objects are considered. A new dataset was created, which includes about 66 thousand objects of various functional affiliations in the territory of the Russian Federation. The stages of data preparation, feature extraction and the process of normalizing the objects' geometries on the map are considered. Experiments were conducted using machine learning methods, including artificial intelligence methods. The research results show that the maximum classification accuracy using a graph neural network is 83 %, which makes the proposed approach promising for practical applications in geographic information systems. A number of factors have been identified that reduce the classification accuracy associated with the insufficiency of geometric information and the shape details common for buildings of certain categories in real development conditions. Recommendations are given for improving the classification accuracy by optimizing the neural network architecture and expanding the feature set. Thus, the article proposes an effective approach to the automated classification of buildings and structures based on the analysis of geometric properties and the environment, which can significantly facilitate the processes of design and infrastructure management.

Keywords: classification, machine learning, coordinate transformation, geometric characteristics, geographic information system, random forest method, graph neural network, GIS.

For citation: Smolev A.M., Golovnin O.K. Machine learning classification of buildings by function using geospatial data. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=2057> DOI: 10.26102/2310-6018/2025.51.4.014

Введение

Одной из наиболее значимых и востребованных задач в сфере геоинформатики и пространственной бизнес-аналитики, позволяющей ответить на множество прикладных вопросов в разных сферах человеческой деятельности, выступает задача обнаружения и классификации объектов на изображениях аэро- и космосъемки, полученных с помощью средств дистанционного зондирования Земли. Развитие технологий обработки изображений, компьютерного зрения и искусственного интеллекта позволяет получать информацию о существующих объектах при проектировании инфраструктуры, обеспечивающей жизнедеятельность современного общества, включая транспорт, водоснабжение, энергетику, телекоммуникации. Информация о стационарных объектах необходима для городского планирования и управления, особенно в урбанизированной среде, где здания являются основной пространственной единицей [1]. Задача классификации стационарных объектов, включая здания и сооружения, также возникает при формировании кадастра недвижимости [2], демографическом и социально-экономическом моделировании [3] и при ликвидации последствий чрезвычайных ситуаций [4].

При решении указанных задач применяются специальные программные средства, упрощающие эту работу посредством систематизации и визуализации пространственной информации – геоинформационные системы (ГИС) и приложения на их основе [5]. Решение задачи инфраструктурного проектирования требует в том числе наличия полной информации о типах зданий и сооружений, и в развитой городской местности эта информация уже присутствует в достаточно точном виде в открытых картографических источниках. Однако в новых районах, а также в отдаленной либо сельской местности, информация о зданиях и их типах может отсутствовать, в связи с чем возникает необходимость извлечения этих данных из доступных материалов – спутниковых либо аэрофотоснимков дистанционного зондирования Земли. Задача распознавания зданий и сооружений и их выделения из фона на изображениях изучалась многими исследователями [6, 7], и ее можно считать в целом решенной. Задача же определения типов зданий и сооружений по тем же источникам обращала на себя куда меньшее

внимание из-за того, что далеко не всегда можно собрать достаточное количество классификационных признаков для ее решения с точностью, обычно требуемой при решении подобных задач. Тем не менее, для применения в современных ГИС полезным может быть и приближенное решение, поскольку оно позволит оценить территориальное распределение объектов по типам и снизить объем работы.

С учетом вышесказанного, вклад данной работы в развитие темы состоит в следующем:

- создан новый набор данных о зданиях и сооружениях, пригодный для решения задачи классификации методами машинного обучения и искусственного интеллекта;
- выполнена адаптация и проверка эффективности различных классификационных методов для анализа набора данных о зданиях и сооружениях;
- достигнута точность классификации зданий и сооружений исключительно по геометрическим и атрибутивным признакам в 83 %, достаточная для практического применения результатов работы.

Современные методы классификации зданий и сооружений. Основные способы решения проблемы можно разделить на три основные категории, различающиеся типом входных данных.

Использование геометрических характеристик. В этом случае исходными данными являются контур здания, т. е. его граница в виде замкнутой линии, и окружение здания. Под окружением подразумеваются показатели, характеризующие свойства местности, где расположено здание. В первую очередь это информация о плотности застройки вокруг здания, т. е. доли застроенной территории, и о видах землепользования в окрестности здания. Контур и окружение являются единственной информацией о здании, которую можно сравнительно быстро и с минимальными затратами извлечь из географических ресурсов, например, ГИС.

В качестве входных параметров используются выводимые на основе контура характеристики здания, в том числе площадь, периметр, вытянутость, количество углов. При выполнении классификации, как правило, используются классические методы машинного обучения. К ним относятся метод опорных векторов, деревья решений и случайный лес. Источниками массивов данных, используемых при классификации, могут являться векторные географические карты, растровые топографические и ортофотопланы, а также базы трехмерных моделей зданий. Методы машинного обучения использовались при классификации зданий в Цюрихе, Дрездене, Галле и других городах и селах Германии [8].

Преимуществами такого подхода являются время выполнения и способность объяснить результаты классификации. Основным недостатком является невысокая точность классификации, особенно при отсутствии трехмерных моделей зданий [8]. В такой ситуации единственной информацией о конкретном здании является форма его крыши, часто не позволяющая однозначно определить его назначение. Тем не менее, этот подход может быть применен для предварительной обработки, поскольку его результаты позволят выбрать нужное направление дальнейших исследований.

Использование графов. Как и в первом подходе, исходной информацией является контур и окружение здания, получаемые с помощью ГИС. Однако входными данными для методов классификации являются не геометрические характеристики здания и его окрестности, а их графовая модель. При преобразовании контура здания в граф его вершинами становятся углы здания, а ребрами – стены между ними. Такой способ описания позволяет аналитически задавать показатель схожести двух зданий, который будет участвовать в дальнейшей классификации [9]. При преобразовании окрестности за вершины обычно берут центроиды близлежащих зданий, а выбор ребер зависит от

метода построения графа – например, нахождение минимального остовного дерева либо триангуляция Делоне [10].

На втором этапе выполняется преобразование графа в вектор числовых признаков, позволяющий использовать методы машинного обучения, в том числе глубокого обучения, такие как графовые сверточные нейронные сети. На данный момент подробно описаны два способа: применение автокодировщика [11] и графовое преобразование Фурье [10]. Последний способ дает возможность использовать для изучения графов алгоритмы линейной алгебры и математический анализ. Основой для числового описания графа является матрица Кирхгофа и связанное с ней графовое преобразование Фурье. Это преобразование применяется для взвешенного графа, где каждая вершина помечена некоторым вещественным числом. Собственные вектора отсортированы по возрастанию соответствующих им собственных чисел матрицы Кирхгофа [10].

Преимущество этого способа заключается в сохранении большего количества информации о форме отдельных частей зданий, особенно в случаях, когда они обладают мелкими выступами либо своеобразной архитектурой, что расширяет применимость данного метода. Основной недостаток, как и у первого подхода – недостаточность исходной информации. Поэтому в задаче классификации зданий применение графов не всегда обеспечивает повышение точности по сравнению с геометрическими характеристиками [10, 12]. Кроме того, преобразование графа окрестности здания требует значительного количества вычислительных ресурсов и поэтому может выполняться чрезвычайно долго [10].

Использование графической информации. В случаях, когда необходимо повысить точность классификации зданий, прибегают к обработке данных, полученных средствами дистанционного зондирования Земли. К ним относятся спутниковые снимки [13], аэрофотоснимки, получаемые лидаром изображения [14] и другие растровые данные. В недавних работах для классификации зданий также применялись панорамы в картографических сервисах, в первую очередь Google Street View [3, 15]. Обычные сверточные сети могут использоваться для классификации отдельных зданий либо городских кварталов [16]. Преимуществом такого подхода является более высокая точность классификации, недостатком – необходимость в объемном массиве графических данных, часто отсутствующих в открытом доступе. Так, для того чтобы на спутниковых изображениях можно было однозначно различить здания, их разрешение (т.е. длина одного пикселя) не должно превышать 1 м. Однако снимки такого разрешения в основном принадлежат зарубежным компаниям Maxar Technologies и Airbus и не находятся в открытом доступе. В российских исследованиях для анализа информации дистанционного зондирования Земли используются снимки, полученные спутниками Landsat и Sentinel, имеющие минимальное разрешение 10 м и непригодные для выделения и сегментации зданий [17]. Поскольку для обучения нейронных сетей требуется достаточный массив данных – до сотен тысяч снимков в высоком качестве, их загрузка вызывает затруднения на практике.

Помимо вышеперечисленных, существуют и другие способы классификации зданий, например, по содержащимся в них географическим меткам, обозначающим те или иные точки притяжения (магазины, рестораны, госучреждения) [1], либо по данным кадастра и переписи населения [18]. Однако исходные данные такого рода могут встречаться лишь в местах, где картографические данные уже высоко детализированы, что означает, что здания, скорее всего, уже отсортированы по типам и поэтому такой способ классификации не применим в рассматриваемом нами случае.

Дополнительным фактором, влияющим на качество процесса классификации, является способ разделения зданий и сооружений на типы. В общей сложности

различными исследователями было предложено более 30 способов осуществления классификации землепользования, от которых зависит и классификация зданий [19]. Конкретный способ классификации зависит как от исследуемой локации, так и от целей проводимого исследования. Например, при автоматическом распределении зданий по типам частные и многоквартирные жилые дома часто рассматриваются отдельно, так как их несложно отличить по геометрии, что повышает точность классификации [8]. В данной работе применяется классификация, используемая для осуществления инвентаризационных работ в специализированных ГИС [20, 21].

Материалы и методы

Первой и наиболее важной фазой исследования является создание набора данных, который будет использоваться для обучения и тестирования классификаторов зданий. Данный набор должен обладать качествами, делающими его пригодными для использования как обучающего, а именно, содержать значительное число объектов – несколько десятков тысяч, широкий набор значимых признаков, а также равномерное распределение объектов по классам. Последнего добиться особенно сложно ввиду естественной асимметрии в реальных наборах данных: как правило, более 90 % зданий являются жилыми, особенно в сельской местности. Это приводит к необходимости использовать обширный участок карты для сбора данных.

В качестве источника информации взята пространственная база данных ГИС, основанная на данных открытого картографического сервиса OpenStreetMap, в которой реализована система типизации зданий и строений [22]. В базе данных присутствуют школы и детские сады с типовой планировкой в застраивавшихся в период СССР микрорайонах, как на Рисунке 1а, что выделяет их среди зданий других типов, часто не отличимых друг от друга, как на Рисунке 1б.




Рисунок 1 – Геометрии отпечатков зданий: а – детский сад (розовый) и школа (фиолетовый);
б – жилые дома (желтый) и офисные здания (оранжевый)

Figure 1 – Building trace geometries: а – kindergarten (pink) and school (purple);
b – residential houses (yellow) and office buildings (orange)

Набором исходных данных в рассматриваемой задаче является массив кортежей $\langle B_i, Q_i \rangle, i = \overline{1, N}$, при этом каждая B_i – это последовательность координат контура здания $B_i = \{(x_j, y_j)\}_{j=1}^{k_i}$, в которой k_i – число координат в контуре здания i , N – общее число

зданий в наборе данных, Q_i – тип здания, характеризующий его назначение. Q_i может принимать следующие значения:

- жилые здания;
- промышленные здания;
- торговые и офисные здания;
- гаражи;
- образовательные учреждения (школы, вузы);
- детские сады;
- сельскохозяйственные сооружения (элеваторы, теплицы и т. п.).

Таким образом, метод классификации должен присваивать тип $\tilde{Q}_i$ каждому зданию i на основе только информации о его контуре P_i и, при доступности, контурах некоторых соседних зданий, так, чтобы он оказался равным Q_i с как можно большей вероятностью.

Перед применением методов машинного обучения необходимо выделить гомогенные признаки в наборе контуров P_i . Использовать исходные данные непосредственно невозможно из-за разного количества числовых координат в каждом P_i . Нами используются два способа выведения признаков из P_i , позволяющих гомогенизировать ряды параметров между объектами, для их включения в тренировочный набор данных.

Первый вариант основывается на применении геометрических характеристик полигонов зданий. К ним относятся свойства геометрии здания, свойства прилегающей территории и семантический параметр. Геометрические свойства здания включают в себя:

- 1) число вершин геометрии (углов здания) N ;
- 2) площадь отпечатка здания S ;
- 3) периметр здания (длина контура) P ;

4) длина наименьшего описанного прямоугольника L_{Rmin} . Под наименьшим описанным прямоугольником подразумевается прямоугольник R_{min} , описанный вокруг здания B , с минимально возможной площадью, т. е. для которого выполняется условие:

$$S(R_{min}) = \min_{R \supseteq B} S(R); \quad (1)$$

- 5) ширина наименьшего описанного прямоугольника B_{Rmin} ;
- 6) площадь выпуклой оболочки полигона здания S_{cv} ;
- 7) среднее расстояние от центроида геометрии C до ее вершин A_i D_a :

$$D_a = \frac{\sum_{i=1}^N |CA_i|}{N}; \quad (2)$$

- 8) максимальное расстояние между двумя вершинами D_{max} :

$$D_{max} = \max_{1 \leq i, j \leq N} |A_i A_j|; \quad (3)$$

- 9) Площадь отверстий в полигоне S_h .

Характеристики прилегающей к зданию территории:

- 1) количество зданий N_n ;
- 2) доля застроенной территории F_n ;
- 3) доля территории, занятая выпуклыми оболочками зданий F_{cv} .

Семантическим параметром является признак нахождения здания в городской либо сельской местности.

Второй рассмотренный способ заключается в непосредственном использовании границы здания. В этом случае признаками классификации становятся значения из

массива, состоящего из K координат точек на границе здания. При этом требуется, чтобы величина K была одинакова у всех зданий – только так можно обеспечить гомогенность значений каждого отдельно взятого признака. Для этого выполняется нормализация геометрий каждого здания. Нормализация решает две задачи – приведение числа вершин к K и устранение сдвига и поворота зданий друг относительно друга таким образом, чтобы у зданий одинаковой формы значения каждого координатного признака как можно меньше отличались друг от друга.

Предположим, у нас есть исходный набор точек P_{0i} с координатами (X_{0i}, Y_{0i}) . В первую очередь требуется расширить или сократить набор вершин геометрии, чтобы их число стало равным заданному K . Если количество вершин в исходной геометрии уже равно K , набор вершин не меняется. В противном случае выполняется один из алгоритмов – увеличения или уменьшения числа вершин до K .

Рассмотрим алгоритм увеличения числа вершин. Работа производится над множеством отрезков исходной геометрии. Каждому отрезку x присваиваются значения $Sep(x)$, изначально равному длине отрезка, и $NS(x)$, равному 0. По ходу увеличения итеративным методом определяется отрезок L между вершинами исходной геометрии, текущая величина $Sep_i(L)$ которого максимальна. Инкрементируется величина $NS_{i+1}(L) = NS_i(L) + 1$, после чего рассчитывается новая величина:

$$Sep_{i+1}(L) = \frac{Sep_0(L)}{NS_{i+1}(L)}. \quad (4)$$

После завершения этого процесса каждый отрезок исходной геометрии с величиной $NS_{K-N}(L) > 0$ делится на равные промежутки $NS_{K-N}(L)$ точками. Тем самым повышается степень равноудаленности вершин геометрии.

При уменьшении количества вершин таким же итеративным способом находится набор трех соседних вершин, ограничивающих два отрезка L и M , таких, что $|L| + |M| \rightarrow \max$, после чего точка между двумя этими отрезками удаляется. Это действие повторяется, пока в геометрии не останется N вершин.

После преобразования массива вершин геометрии осуществляется ее сдвиг. В его ходе левая вершина геометрии вдоль длиннейшей оси (j либо l) перемещается в точку $(0, 0)$, и такое же преобразование проводится со всеми вершинами:

$$X_{2i} = X_{1i} - X_{1j}; Y_{2i} = Y_{1i} - Y_{1j}. \quad (5)$$

На последнем этапе производится устранение относительного поворота геометрии. Этого можно достичь нахождением самой длинной оси геометрии $D_{\max}$. Находим две самые удаленные друг от друга вершины – пусть это будут j и l :

$$\text{dist}(j, l) = \sqrt{(Y_{0l} - Y_{0j})^2 + (X_{0l} - X_{0j})^2} \rightarrow \max. \quad (6)$$

Далее находим угол поворота этой оси относительно Ox и разворачиваем всю геометрию на угол, противоположный найденному. Поворот геометрии осуществляется относительно точки $(0, 0)$, поскольку нам необходимо сохранить левую точку в этом положении. После выполнения операции координаты j и l будут иметь одинаковое (нулевое) значение y , а сама геометрия приобретает вид, который будет использоваться при ее классификации методами машинного обучения. Поскольку координата j всегда равна $(0, 0)$, мы делаем ее первой в списке координат и исключаем из признаков классификации, а обход остальных координат выполняется всегда в одну сторону, начиная от точки j , чтобы устранить влияние направления обхода на признаки классификации.

По итогам сбора исходных данных было получено 65838 записей о строениях, распределенных по указанным типам. Количество зданий каждого типа,

присутствующих в выборке, приведено в Таблице 1. Выборка из полной БД осуществлялась так, чтобы снизить уровень несбалансированности в наборе данных, отрицательно влияющей на эффективность методов машинного обучения [22], а также по возможности охватить как городскую, так и сельскую местность. Информация о жилых и промышленных зданиях извлекалась только из карты Самарской области. Информация о зданиях других типов более обширна: в наборе данных содержатся записи о гаражах в 4 регионах, о торговых и офисных зданиях в 7 регионах, а о детских садах, школах и сельскохозяйственных сооружениях – в 13 регионах Российской Федерации.

Таблица 1 – Распределение зданий по типам
Table 1 – Building type distribution

Тип	Количество
Строения. Жилые	12752
Строения. Промышленные	12164
Строения. Гаражи	11822
Строения. Торговые и офисные	11074
Строения. Образовательные	7675
Строения. Детские сады	5972
Строения. Сельскохозяйственные	4379

Классификация зданий и сооружений осуществлялась следующими методами машинного обучения:

- метод опорных векторов;
- дерево решений;
- метод ближайших соседей;
- метод случайного леса;
- метод на основе полносвязной нейронной сети, использующей при классификации информацию только о текущем здании;
- метод на основе графовой нейросети, которая дополнительно учитывает свойства зданий, соседних с рассматриваемым.

Получение информации о прилегающей территории и о местности нахождения здания производилось средствами СУБД *PostgreSQL* с геопространственным расширением *PostGIS*, используемыми для хранения данными в ГИС. Вычисление геометрических характеристик полигонов, а также нормализация геометрий выполнялись посредством библиотеки *Shapely* для языка *Python*. Классификация методами машинного обучения с учителем осуществлялась с помощью библиотеки *scikit-learn*. Классификация полносвязной нейронной сетью была выполнена посредством библиотек *TensorFlow* и *keras*, а построение и обучение графовой нейронной сети производились средствами *PyTorch Geometric*. Данная библиотека позволяет ускорить обучение за счет объединения графов с разным числом вершин посредством конкатенации матриц признаков X_G и откликов Y_G графов, а также размещением матриц смежности A_G на главной диагонали общего графа, где остальные элементы равны нулю:

$$A = \begin{bmatrix} A_{G_1} & & 0 \\ & \ddots & \\ 0 & & A_{G_m} \end{bmatrix}; \quad X = \begin{bmatrix} X_{G_1} \\ \dots \\ X_{G_m} \end{bmatrix}; \quad Y = \begin{bmatrix} Y_{G_1} \\ \dots \\ Y_{G_m} \end{bmatrix}. \quad (7)$$

Результаты

Сначала рассмотрим результаты классификации с помощью методов машинного обучения. Определено, что методы опорных векторов и дерево решений не позволяют добиться точности классификации выше 50 %, что говорит об их неприменимости в данной задаче. Метод *k-neighbors* при числе соседей, равным семи, показал точность 57 %. Более же высокую точность – 66 % – показал метод случайного леса со 100 деревьями, метрика f1-score оказалась равной 65 %. При анализе влияния включения геометрических характеристик и нормализованных координат ($K = 20$) было найдено, что использование координат не приводит к увеличению точности классификации при данном выборе признаков. Это говорит о том, что геометрические характеристики уже поглощают всю влияющую на класс сооружения информацию. Уменьшение размерности пространства признаков до 7 с помощью метода главных компонент (PCA), где первые 7 компонент объясняют 99 % вариативности, снижает точность классификации до 60 %, что говорит о значимости всех рассматриваемых характеристик.

Далее тестировалась возможность с помощью нейронных сетей повысить точность классификации. Сначала была осуществлена классификация посредством полносвязной глубокой нейронной сети, содержащей три слоя по 100 нейронов. Точность при обучении не превышала 64 %, из чего можно сделать вывод, что добиться точности выше, чем для метода случайного леса, едва ли удастся. Следовательно, нужно расширять набор классификационных признаков.

В этих целях была осуществлена адаптация графовой нейронной сети *GraphSAGE* для осуществления классификации зданий и сооружений России. Однако, прежде чем проводить классификацию, необходимо преобразовать исходный набор данных в массив классифицируемых графов. Во-вторых, для каждого здания был построен граф окрестности $G_n = (V_n, E_n)$, содержащий информацию о ближайших зданиях B_n в пределах 2,5 км от анализируемого. Число вершин в графе $|V_n|$, т. е. число рассматриваемых зданий, будем обозначать n . Каждому зданию B_{n_i} соответствует узел в графе V_{n_i} . Ребра между узлами E_{n_i} строятся по принципу триангуляции Делоне, требующему, чтобы окружность, проведенная через составляющие треугольник узлы, не содержала внутри себя других узлов графа.

Сеть *GraphSAGE* [23], адаптированная для осуществления классификации зданий и сооружений России, состоит из следующих слоев:

- линейный полносвязный слой, принимающий на вход пакетное объединение из P графов и возвращающий на выходе 512 признаков;
- $Count_l$ слоев свертки *SAGE* размера 512×512 , преобразующие входные данные по правилу:

$$y_i = W_1 x_i + W_2 \frac{\sum_{j \in N(i)} x'_j}{|N(i)|}; \quad (8)$$

$$x'_j = \sigma(W_3 x_j + b), \quad (9)$$

где x_i – входной массив признаков здания с вершиной i ; $N(i)$ – множество вершин, смежных с i ; σ – нелинейная функция активации; W_k , $k = 1..3$, b – веса обучаемых нейронов в слое *SAGE*; y_i – выходные признаки слоя;

- линейный полносвязный слой, преобразующий выход последнего слоя *SAGE* к массиву из 7 признаков;

– применение функции $\log(\text{softmax}(y_i))$ для последующего расчета ошибок нейронной сети с помощью функции потерь по отрицательному логарифму вероятности $NLLLoss$.

Обучение нейронной сети осуществлялось в течение 50 эпох, уровень исключения весов нейронов при обучении был установлен величиной 0,2. Из общего набора данных 20 % элементов было зарезервировано под тестовую выборку.

Первый этап адаптации состоял в подборе гиперпараметров и нахождении оптимальной архитектуры нейросети для максимизации точности классификации. К этим параметрам относятся:

- количество слоев графовой свертки в нейронной сети $Count_l$;
- количество нейронов в каждом слое графовой свертки N_l ;
- вид функции активации;
- скорость обучения нейросети lr .

При тестировании *GraphSAGE* были найдены следующие величины, при которых точность классификации на тестовой выборке становится максимальной и далее не повышается: $Count_l = 4$, $N_l = 512$, $lr = 10^{-4}$. В качестве функции активации была взята Adam.

На втором этапе проверено влияние количества объектов n в графе окрестности G_n на точность и на скорость классификации. При исходной величине графа $n = 20$ значение F1-score для результатов классификации составило 77 % – рост на 11 % по сравнению с методом случайного леса. Более того, было найдено, что при увеличении n происходит значимый рост точности классификации. Из графика на Рисунке 2 следует, что при максимальном значении $n = 100$ F1-score составляет 83 %.




Рисунок 2 – Зависимость показателя *F1-score* от объема графа G_n

Figure 2 – *F1-score* dependence on the G_n graph size

Исходя из графика, можно предположить, что дальнейшее повышение n позволило бы еще повысить этот показатель, однако в таком случае будет усложнена работа с объектами, находящимися на краю или за пределами застроенной территории, поскольку в графе соседних объектов будут оказываться сооружения, находящиеся далеко от объекта и в связи с этим не дающие полезную информацию о его назначении.

Оценка скорости обучения и классификации выполнялась на вычислительном устройстве со следующими параметрами: CPU – Intel Core i7-12700K; GPU – Nvidia GeForce RTX 3060; версия PyTorch 2.5.1 и версия CUDA 11.8. При росте n , начиная с 20, продолжительность обучения модели увеличивается, как показано на Рисунке 3а, а скорость классификации – уменьшается, что продемонстрировано на Рисунке 3б. Несмотря на это, скорость 3300 объектов при использовании 100 объектов в графе более чем достаточна для проведения полной масштабной классификации объектов на

обширной территории Российской Федерации, поскольку по сравнению с данной скоростью, спутниковые снимки и исходные геометрические данные обновляются на порядок реже.




Рисунок 3 – Скорость обучения (а) и классификации (б) *GraphSAGE*
Figure 3 – *GraphSAGE* training (a) and classification (b) rate

Результаты классификации наиболее точных методов представлены в Таблице 2. В этой таблице P (precision) означает точность классификации, R (recall) – полноту, а под обозначением F1 дается показатель F1-score. Через n обозначено количество сооружений в графе соседей классифицируемого здания.

Таблица 2 – Точность классификации зданий
Table 2 – Building classification accuracy

Тип здания/ Метод	<i>k-neighbors</i>			<i>Random forest</i>			<i>GraphSAGE</i> ($n = 20$)			<i>GraphSAGE</i> ($n = 100$)		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
жилые	0,59	0,76	0,67	0,73	0,79	0,76	0,79	0,88	0,83	0,90	0,94	0,92
промышленные	0,54	0,58	0,56	0,59	0,65	0,62	0,76	0,81	0,78	0,87	0,84	0,86
торговые и офисные	0,38	0,29	0,33	0,47	0,44	0,45	0,62	0,76	0,69	0,74	0,76	0,75
гаражи	0,60	0,61	0,61	0,71	0,72	0,72	0,93	0,79	0,86	0,90	0,88	0,88
образовательные	0,63	0,59	0,61	0,72	0,67	0,69	0,80	0,70	0,75	0,85	0,70	0,78
детские сады	0,56	0,55	0,55	0,70	0,69	0,70	0,80	0,65	0,72	0,77	0,72	0,76
сельскохозяйственные	0,68	0,47	0,55	0,76	0,56	0,65	0,87	0,76	0,82	0,90	0,86	0,88
Общая	0,57	0,55	0,56	0,66	0,65	0,65	0,77	0,77	0,77	0,83	0,83	0,83

Обсуждение

В ходе исследований выявлены возможные источники ошибок при классификации зданий. Точечные диаграммы зависимости типа здания от S , P , L_{Rmin} и B_{Rmin} представлены на Рисунках 4 и 5. На них отражается значительное наложение групп объектов каждого из типов зданий, что говорит о недостаточности исключительно геометрической информации об объектах. Графики для отдельных параметров прилегающей территории не демонстрируют видимой зависимости от них типа здания, что означает, что их значимость проявляется только при рассмотрении совместно с другими факторами.




Рисунок 4 – Зависимость периметра от площади здания по типам
Figure 4 – Dependence of perimeter on building area by type




Рисунок 5 – Зависимость длины и ширины минимального описанного прямоугольника от типа
Figure 5 – Dependence of the length and width of the minimum circumscribed rectangle on the type

Наиболее высокая точность классификации свойственна жилым домам. Происходит это благодаря относительной простоте классификации частных домов, которые занимают основную долю в слое жилых зданий. Это достигается за счет их сравнительно низкой площади и их характерной квадратной формы. Также довольно

высокая точность была достигнута при классификации гаражей – их характерными чертами являются продолговатая форма зданий и высокая плотность застройки, где свободная площадь оставлена только под проезжую часть. Наиболее низкая точность классификации была зафиксирована для торговых и офисных зданий, что объясняется отсутствием специфичной формы и отсутствием зависимости их расположения от плотности застройки. Точности классификации детских садов и образовательных учреждений не превышает точность для остальных видов объектов. Было найдено, что в случайной выборке из 45 детских садов 13 имеют обычный четырехугольный вид, что не позволяет с уверенностью отличить их от жилых зданий.

Заключение

Таким образом, в работе проанализирована задача классификации зданий и сооружений по их функциональному назначению на основе пространственной информации. В рамках работы найдена и собрана информация о зданиях и сооружениях Российской Федерации, из которой составлен набор данных, предназначенный для решения задачи классификации методами машинного обучения. Осуществлены анализ и адаптация классических и нейросетевых методов классификации зданий по данным дистанционного зондирования Земли, предназначенных для применения в процессе разработки детализованных карт в ГИС.

Наиболее эффективным средством определения назначения зданий стали графовые нейронные сети, что объясняется более широким набором признаков, используемых при классификации с их помощью. При классификации посредством графа соседних зданий удалось значимо повысить точность классификации сооружений в Российской Федерации за счет увеличения числа вершин в графе. Достигнута точность классификации зданий и сооружений исключительно по геометрическим и атрибутивным признакам в 83 %.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Chen W., Zhou Yu., Wu Q., Chen G., Huang X., Yu B. Urban Building Type Mapping Using Geospatial Data: A Case Study of Beijing, China. *Remote Sensing*. 2020;12(17). <https://doi.org/10.3390/rs12172805>
2. Gummidi S.R.Bh., Mao R., Lanau M., Liu G. Developing an Urban Resource Cadaster for Circular Economy. In: *Circular Economy for Buildings and Infrastructure: Principles, Practices and Future Directions*. Cham: Springer; 2024. P. 83–95. https://doi.org/10.1007/978-3-031-56241-9_6
3. Xie Ju., Zhou J. Classification of Urban Building Type from High Spatial Resolution Remote Sensing Imagery Using Extended MRS and Soft BP Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2017;10(8):3515–3528. <https://doi.org/10.1109/JSTARS.2017.2686422>
4. Li J., Huang X., Tu L., Zhang T., Wang L. A Review of Building Detection from Very High Resolution Optical Remote Sensing Images. *GIScience & Remote Sensing*. 2022;59(1):1199–1225. <https://doi.org/10.1080/15481603.2022.2101727>
5. Иващенко А.В., Головнин О.К., Головнина А.А., Додонова Е.А. Комбинированная геоинформационная многослойная пространственно-временная модель. *Информатика и автоматизация*. 2025;24(2):684–711. <https://doi.org/10.15622/ia.24.2.12>
Ivaschenko A., Golovnin O., Golovnina A., Dodonova E. An Assembled Model of Multilayer Geoinformation Space-Time. *Informatics and Automation*. 2025;24(2):684–711. (In Russ.). <https://doi.org/10.15622/ia.24.2.12>

6. Баранова И.В., Гилян С.В. Гибридный алгоритм распознавания строений на спутниковых снимках на основе метода жука и алгоритма исключения областей. *Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика*. 2024;13(2):56–76. <https://doi.org/10.14529/cmse240204>
Baranova I.V., Gilin S.V. Building Recognition Hybrid Algorithm for Satellite Images Based on the Beetle Method and the Area Exclusion Algorithm. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2024;13(2):56–76. (In Russ.). <https://doi.org/10.14529/cmse240204>
7. Галеев Д.Т., Мирошниченко С.Ю. Применение искусственных нейронных сетей для решения задачи выделения зданий на аэрокосмических изображениях. В сборнике: *Опτικο-электронные приборы и устройства в системах распознавания образов и обработки изображений. Распознавание-2019: сборник материалов XV Международной научно-технической конференции, 14–17 мая 2019 года, Курск, Россия*. Курск: Юго-Западный государственный университет; 2019. С. 64–66.
8. Hecht R., Meinel G., Buchroithner M. Automatic Identification of Building Types Based on Topographic Databases – A Comparison of Different Data Sources. *International Journal of Cartography*. 2015;1(1):18–31. <https://doi.org/10.1080/23729333.2015.1055644>
9. Lu X., Li H., Xu Yo., Liu J., Chen Zh. Measuring the Similarity Between Shapes of Buildings Using Graph Edit Distance. *International Journal of Digital Earth*. 2024;17(1). <https://doi.org/10.1080/17538947.2024.2310749>
10. Yan X., Ai T., Yang M., Yin H. A Graph Convolutional Neural Network for Classification of Building Patterns Using Spatial Vector Data. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2019;150:259–273. <https://doi.org/10.1016/j.isprsjprs.2019.02.010>
11. Yan X., Ai T., Yang M., Tong X. Graph Convolutional Autoencoder Model for the Shape Coding and Cognition of Buildings in Maps. *International Journal of Geographical Information Science*. 2021;35(3):490–512. <https://doi.org/10.1080/13658816.2020.1768260>
12. Hu Ya., Liu Ch., Li Zh., Xu Ju., Han Zh., Guo J. Few-Shot Building Footprint Shape Classification with Relation Network. *ISPRS International Journal of Geo-Information*. 2022;11(5). <https://doi.org/10.3390/ijgi11050311>
13. Kang J., Körner M., Wang Yu., Taubenböck H., Zhu X.X. Building Instance Classification Using Street View Images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2018;145:44–59. <https://doi.org/10.1016/j.isprsjprs.2018.02.006>
14. Roussel R., Jacoby S., Asadipour A. Robust Building Identification from Street Views Using Deep Convolutional Neural Networks. *Buildings*. 2024;14(3). <https://doi.org/10.3390/buildings14030578>
15. Huang Yu., Zhuo L., Tao H., Shi Q., Liu K. A Novel Building Type Classification Scheme Based on Integrated LiDAR and High-Resolution Images. *Remote Sensing*. 2017;9(7). <https://doi.org/10.3390/rs9070679>
16. Игнатъев А.В., Гилка В.В., Матыцына Д.А. Автоматическое распознавание типа застройки для системы экологического мониторинга. *Инженерный вестник Дона*. 2020;(1). URL: <http://www.ivdon.ru/ru/magazine/archive/N1y2020/6266>
Ignatyev A.V., Gilka V.V., Matytsyna D.A. Automatic Recognition of Building Type for Environmental Monitoring System. *Engineering Journal of Don*. 2020;(1). (In Russ.). URL: <http://www.ivdon.ru/en/magazine/archive/N1y2020/6266>
17. Рязанов С.С., Кулагина В.И. Обзор российских и иностранных источников мультиспектральных снимков для создания систем агроэкологического

- мониторинга. *Российский журнал прикладной экологии*. 2024;(2):4–18. <https://doi.org/10.24852/2411-7374.2024.2.04.18>
- Ryazanov S.S., Kulagina V.I. A Review of Russian and Foreign Sources of Multispectral Imagery for Agroecological Monitoring Systems Development. *Russian Journal of Applied Ecology*. 2024;(2):4–18. (In Russ.). <https://doi.org/10.24852/2411-7374.2024.2.04.18>
18. Bbandam A., Busari E., Syranidou Ch., Linssen J., Stolten D. Classification of Building Types in Germany: A Data-Driven Modeling Approach. *Data*. 2022;7(4). <https://doi.org/10.3390/data7040045>
19. Lehner A., Blaschke Th. A Generic Classification Scheme for Urban Structure Types. *Remote Sensing*. 2019;11(2). <https://doi.org/10.3390/rs11020173>
20. Михеева Т.И., Головнин О.К., Елизаров В.В. Стандарт дислокации и визуализации геообъектов на электронной карте в среде ITSGIS. В сборнике: *Современные проблемы безопасности жизнедеятельности: интеллектуальные транспортные системы и ситуационные центры, 27–28 февраля 2018 года, Казань, Россия*. Казань: Центр инновационных технологий; 2018. С. 261–269.
Mikheeva T.I., Golovnin O.K., Elizarov V.V. Standard of Dislocation of Technical Equipment of Organization of Road Traffic and Geoobjects of the Street-Road Network on the Electronic Map. In: *Modern Problems of Life Safety: Intelligent Transport Systems and Situational Centers: Collection of Materials of V International Research and Practice Conference, 27–28 February 2018, Kazan, Russia*. Kazan: Center for Innovation Technologies; 2018. P. 261–269. (In Russ.).
21. Смолев А.М., Михеева Т.И., Золотовицкий А.В. Методы моделирования адресного плана в рамках геоинформационной системы. В сборнике: *ИТ & Транспорт: сборник научных статей: Том 24*. Самара: ИнтелТранС; 2023. С. 4–13.
Smolev A.M., Mikheeva T.I., Zolotovitsky A.V. Methods of Modeling an Address Plan Within the Framework of Geographic Information System. In: *IT & Transport: sbornik nauchnykh statei: Volume 24*. Samara: IntelTranS; 2023. P. 4–13. (In Russ.).
22. Зуев В.Н. Обнаружение аномалий сетевого трафика методом глубокого обучения. *Программные продукты и системы*. 2021;(1):91–97. <https://doi.org/10.15827/0236-235X.133.091-097>
Zuev V.N. Network Anomalies Detection by Deep Learning. *Software & Systems*. 2021;(1):91–97. (In Russ.). <https://doi.org/10.15827/0236-235X.133.091-097>
23. Лыгин В.С., Сирота А.А., Головинский П.А. Регуляризация процесса обучения графовых нейронных сетей методом распространение меток. *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2024;(3):92–101. <https://doi.org/10.17308/sait/1995-5499/2024/3/92-101>
Lygin V.S., Sirota A.A., Golovinski P.A. Regularization of the Learning Process of Graph Neural Networks Using the Label Propagation Method. *Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2024;(3):92–101. (In Russ.). <https://doi.org/10.17308/sait/1995-5499/2024/3/92-101>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Смолев Александр Михайлович, аспирант, **Alexandr M. Smolev**, Postgraduate, Samara Самарский национальный исследовательский National Research University, Samara, the университет имени академика С.П. Королева, Russian Federation. Самара, Российская Федерация.

e-mail: volga04j@gmail.com

ORCID: [0009-0007-1830-7472](https://orcid.org/0009-0007-1830-7472)

Головнин Олег Константинович, доктор технических наук, доцент, заведующий кафедрой медицинской физики, математики и информатики, Самарский государственный медицинский университет, Самара, Российская Федерация.

e-mail: golovnin@bk.ru

ORCID: [0000-0002-1418-2226](https://orcid.org/0000-0002-1418-2226)

Oleg K. Golovnin, Doctor of Engineering Sciences, Docent, Head of the Department of Medical Physics, Mathematics and Computer Science, Samara State Medical University, Samara, the Russian Federation.

Статья поступила в редакцию 27.08.2025; одобрена после рецензирования 23.09.2025; принята к публикации 07.10.2025.

The article was submitted 27.08.2025; approved after reviewing 23.09.2025; accepted for publication 07.10.2025.