

С.В. ЕРЕМЕЕВ, А.В. АБАКУМОВ, Д.Е. АНДРИАНОВ, Т.А. ШИРАБАКИНА
**МЕТОД ВЕКТОРИЗАЦИИ СПУТНИКОВЫХ СНИМКОВ НА
ОСНОВЕ ИХ РАЗЛОЖЕНИЯ ПО ТОПОЛОГИЧЕСКИМ
ОСОБЕННОСТЯМ**

Еремеев С.В., Абакумов А.В., Андрианов Д.Е., Ширабакина Т.А. Метод векторизации спутниковых снимков на основе их разложения по топологическим особенностям.

Аннотация. Получение из растрового изображения объектов в векторном виде необходимо во многих сферах. Существующие методы векторизации спутниковых снимков не обеспечивают нужной точности автоматизации. В данной области требуется применять ручной труд, но объём поступающей информации зачастую превышает скорость обработки. Поэтому необходимы новые подходы для решения подобного рода задач. В статье предложен метод векторизации объектов на снимках с использованием разложения изображения на топологические особенности, который разбивает изображение на отдельные связанные структуры и при дальнейшей работе опирается уже на них. В результате уже на этом этапе изображение разбивается на древовидную структуру. Данный метод уникален по своему образу работы и в корне отличается от традиционных способов векторизации снимков. Большинство методов работает с помощью пороговой бинаризации, и основной задачей для них становится подбор порогового коэффициента. Главной проблемой в таком случае становится ситуация, когда на изображении имеется несколько объектов, для которых необходим разный порог. Метод отходит от непосредственной работы с яркостной характеристикой в сторону анализа топологической структуры каждого объекта. Предлагаемый метод имеет корректное математическое обоснование, в основе которого лежит алгебраическая топология. На основе метода разработана геоинформационная технология для автоматической векторизации растровых снимков с целью поиска находящихся на нем объектов. Тестирование проводилось на спутниковых снимках с разных масштабов. Разработанный метод сравнился со специальным инструментом для векторизации R2V и превзошел его по средней точности. Средний процент у автоматической векторизации предложенного метода составил 81%, а у полуавтоматического векторизирующего модуля R2V – 73%.

Ключевые слова: пространственные данные, разложение изображений, топологические особенности, векторизация.

1. Введение. Геоинформационные системы (ГИС) используют широкий набор различных пространственных данных, среди которых можно выделить растровые изображения, гиперспектральные снимки, векторные объекты, 3D облако точек, 3D поверхности. Для каждого типа пространственных объектов существуют свои методы для анализа и обработки данных. Модели местности в виде растровых изображений позволяют быстро получать актуальную информацию. Однако для компьютерного понимания расположения объектов требуется векторный формат. Кроме того, векторные объекты используют намного меньше компьютерной памяти для хранения объектов, что особенно актуально для передачи данных по сети.

В статье рассматривается задача векторизации пространственных объектов на спутниковых снимках. Под векторизацией понимается процесс перевода растровых изображений в векторный формат. Несмотря на то, что задача векторизации данных решается уже достаточно давно, до сих пор полностью эта задача не решена.

Выделим несколько особенностей, которые затрудняют решение задачи векторизации: насыщенность различных объектов городской инфраструктуры; наличие помех на изображении в виде тени объекта; перекрытие объектов другими объектами, такими как деревья, облака и т.д.

При векторизации пространственные объекты представляются в виде набора геометрических объектов: точки, отрезки, полигоны, сплайны. Рассмотрим подходы, использующие эти примитивы на растровом изображении.

Наиболее часто для решения этой задачи используют преобразование Хафа, основная суть которого заключается в описании прямой в виде выражения: $r = x \cos \theta + y \sin \theta$, где r – это длина нормали, проведенной из начала координат, к прямой, причем $r \geq 0$; θ – это угол между осью абсцисс и нормалью, при этом $\theta \in [0, 2\pi]$. Через каждую точку исходного изображения проводятся прямые с квантованными значениями θ и r . В двумерной таблице, состоящей из параметров θ и r , суммируется количество точек изображения, через которые можно провести прямые с этими параметрами. Локальные максимумы в этой таблице позволяют определить искомые отрезки.

В работе [1] показано использование преобразования Хафа для автоматизированной векторизации. Предварительно пользователь указывает места расположения зданий, имеющих прямоугольную форму. Проводится сегментация в этой области и далее поиск четырех отрезков, образующих здание.

С помощью преобразования Хафа можно выделить объекты произвольной формы, что характерно для пространственных данных на спутниковых снимках. Однако преобразование Хафа целесообразно использовать для объектов простой формы, т.к. для любой формы увеличивается количество параметров, что влечет увеличение вычислительных затрат и усложняет выделение необходимых объектов по этим параметрам. Кроме того, после преобразования Хафа могут образовываться разрывы ломаной линии. Поэтому в этом случае для множества точек на бинарном изображении можно применить

кусочно-линейную аппроксимацию, а также сплайны Безье. Сплайны Безье имеют достаточно простую реализацию, но при этом высокую ошибку соответствия требуемой линии.

В исследовании [2] показано выделение отрезков на изображении в градациях серого. Основу метода PLSD (Persistent Line Segment Detector) составляет использование персистентной гомологии. Сначала для каждой точки на изображении строятся 8 прямых линий с одинаковым углом между любой парой линий, проходящих через точку, по аналогии с преобразованием Хафа, но с меньшим количеством линий. Далее для каждой отдельно взятой линии L рассматриваются значения точек, лежащих на этой линии. Происходит переход от двумерной задачи поиска линий к одномерной. Каждая линия L представляет собой отдельный набор для анализа. Для множества точек на линии L применяется поиск связанных компонент на основе идей топологического анализа данных [3, 4]. Поиск компонент начинается с максимального уровня градации яркости и идет до минимального уровня. Выделяются устойчивые компоненты, которые поглощают другие позже появившиеся компоненты. Для каждого уровня яркости и для каждой линии L анализируются наиболее устойчивые компоненты с продолжительным периодом существования, имеющие наибольшую длину в пикселях, а также наибольший разрыв с соседними компонентами. Те компоненты, которые отвечают этим критериям, являются результатом в виде прямых отрезков.

Метод PLSD хорошо аппроксимирует сложные фигуры. При этом отрезки не пересекаются, что является одним из основных преимуществ метода. Однако, как и в случае с преобразованием Хафа между отдельными отрезками не предусмотрено топологических связей, из-за этого могут быть разрывы на ломаных линиях и полигональных объектах.

Для сохранения топологической согласованности между геометрическими примитивами в статье [5] разработан метод векторизации на основе двунаправленного градиента. Данный метод предназначен и хорошо работает для анализа чертежей с небольшим количеством объектов.

Очень популярным для выделения отрезков и контуров на изображении является алгоритм Канни. Зачастую на спутниковых снимках границы размыты и предпочтительно совместно использовать алгоритм Канни и нечетко-логические методы [6].

Для выделения отрезков на изображении также существуют следующие подходы: LSD [7], EDLines [8]. Недостатком первого

из них является большое количество пропущенных отрезков при увеличении размера изображений, а во втором случае появляется дублирование отрезков. Отметившие эти недостатки авторы статьи [9] решают обозначенную проблему для метода LSD путем разделения изображения на отдельные сегменты меньшего размера.

Отдельную группу составляют алгоритмы для получения контуров зданий в виде полигонов [10]. Для этого применяют волновой алгоритм [11, 12], гиперграфовое представление связанных компонент изображения с дальнейшей полигональной аппроксимацией [13], а также метод на основе триангуляции Делоне [14].

Метод осевых линий [15] предполагает скелетизацию растрового объекта путем его заполнения окружностями максимального радиуса. Центры окружностей соединяются отрезками и представляют собой скелет.

В работе [16] показаны следующие проблемы при автоматическом выделении контуров зданий на изображениях: очень часто контуры не содержат идеально прямых элементов; в одном месте могут сходиться сразу несколько контуров, относящихся к крышам зданий и другим посторонним объектам; границы крыш зданий порождают двойные или тройные контуры.

В отдельный класс методов выделяют подходы, которые используют следующие основные этапы: сегментация объектов, классификация объектов по набору признаков и непосредственно перевод классифицируемого объекта в векторный формат.

Для сегментации используют графовые методы, k-means, EM-алгоритм, алгоритм водораздела, суперпиксельная сегментация, текстурная сегментация по фрактальным характеристикам.

Для классификации применяются различные признаки, включающие статистические, геометрические, структурные, спектральные подходы [17]. Отдельно стоит выделить нейросетевые алгоритмы для классификации объектов [18, 19]: с использованием архитектуры U-Net [20, 21, 22], прогнозирование полигонов на основе сверточной сети графов GCN [23, 24]. В статье [25] каждому пикселю на здании присваивается значение насколько далеко этот пиксель стоит от границы. Если пиксель во внутренней части здания, то значение будет положительным, а иначе отрицательным. Полученные расстояния нормализуются от -1 до 1. После этого идет процесс обучения сверточной нейронной сети. Тем не менее, очень много зависит от правильно выбранного обучающего множества. Стоит использовать те изображения, которые обладают необходимыми свойствами и нужно опасаться значительного преобладания

конкретного свойства в тренировочном множестве, не должны преобладать пустые изображения или изображения, полностью заполненные строениями. Как показано в [26] после выделения зданий методом PPGNet требуется дополнительная постобработка. Кроме того, в сочетании с нейросетью используются дополнительные признаки в виде вейвлетов [27], разложение изображения на основе преобразования Гильберта-Хуанга [28].

Решение задачи векторизации объектов на растровых изображениях с учетом перечисленных особенностей требует поиск новых методов и подходов.

2. Цель исследования. Цель исследования заключается в разработке метода, который позволит распределить пространственные объекты на спутниковом снимке по разным слоям ГИС в векторном виде. Для достижения поставленной цели требуется выделить объекты интереса на изображении. Для этого предполагается использовать оригинальный подход для разложения изображения на топологические особенности. Предлагается две вариации метода: с использованием яркостного разложения изображения и яркостно-метрического.

На основе этого разложения ставится также задача классификации сегментированных областей интереса, т. к. полученные матрицы разложения представляют собой признаки для классификации. Распределенные по выбранным тематическим слоям сегментированные объекты планируется аппроксимировать для получения векторных данных.

3. Основная концепция

3.1. Яркостное разложение изображения по топологическим особенностям (Метод I). В качестве исходных данных будем рассматривать спутниковые снимки, представляющие собой растровые изображения. Эти изображения содержат набор пространственных объектов, подлежащих векторизации. Исходное изображение обозначим в виде матрицы $I = (p_{ij})_{m \times n}$, элементами которой являются пиксели в градациях серого со значениями от 0 до 255, m и n – размеры матрицы. В случае цветных изображений используется стандартный подход RGB (R – Red, G – Green, B – Blue), в котором пиксель описывается тройкой чисел (0..255, 0..255, 0..255).

В основе предлагаемой концепции лежит использование метода разложения изображения на матрицы специального типа: J_1, J_2, \dots, J_q , где q – количество матриц разложения. Теоретические основы

и перспективы практического использования этого метода изложены нами в работе [4].

Покажем основную суть метода и его дальнейшее развитие. Будем рассматривать компоненты, которые соответствуют набору точек на изображении. При анализе компонент возможны следующие ситуации, которые требуют отдельного рассмотрения (рисунок 1):

1. Одновременное появление сразу двух компонент (рисунок 1б).

Изображения рассматриваются слева направо и сверху вниз. Тем самым нумерация компонент идет в порядке их появления. В данном случае сначала появляется первая компонента, которую обозначим как J_1 , а затем вторая, обозначенная как J_2 . Причем J_2 содержит сразу две точки.

2. Присоединение точек к одной из компонент (рисунок 1в).

В примере пиксель со значением 3 присоединяется к компоненте J_2 . Для каждой текущей точки в качестве соседних рассматриваются четыре точки: слева, сверху, справа и снизу.

3. Поглощение одной компоненты другой (рисунок 1г).

Пиксель со значением 2 объединяет сразу две компоненты J_1 и J_2 . Приоритет при поглощении будет у компоненты J_2 т.к. у нее большее количество точек. В качестве критерия при поглощении также можно использовать более ранний порядковый номер компоненты.




Рис. 1. Возможные ситуации при работе с компонентами

Покажем численный пример формирования матриц разложения.

$$\text{Пусть дана матрица } I = \begin{bmatrix} 4 & 5 & 6 & 3 & 5 \\ 1 & 4 & 4 & 3 & 4 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$$

Будем рассматривать сначала все такие точки, что $p_{ij} \geq 7$. Этому условию соответствует лишь одна точка. Будем считать, что появилась первая компонента J_1 .

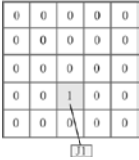
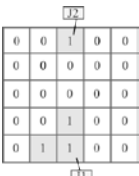
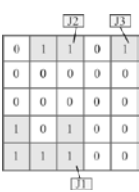
Далее перебираем все пороги $1 \leq T \leq 6$ и по аналогии получаем на каждом шаге бинарное изображение, состоящее из нулей и единиц. Матрицы J_1, J_2, \dots, J_q постепенно заполняются новыми значениями. Размеры каждой из этих матриц совпадают с размерами исходной матрицы. При этом проверяется следующее условие для каждого порога T в случае наращивания матрицы J :

$$b_{ij} = \begin{cases} b_{ij} + 1, & \text{если } a_{ij} = 1 \\ b_{ij}, & \text{иначе} \end{cases},$$

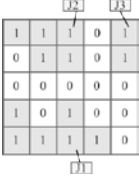
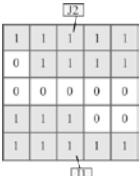
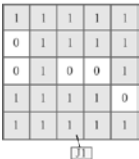
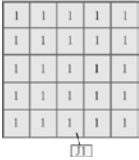
где b_{ij} – текущее значение матрицы J , a_{ij} – бинарная матрица для порога T .

В таблице 1 хорошо видно, что всего было образовано 3 матрицы: J_1 , J_2 и J_3 , начало формирования которых соответствует порогам 7, 6 и 5 соответственно. Кроме того, матрица J_2 поглощает J_3 на пороге 3, а J_1 поглощает J_2 на пороге 2. Критерием при поглощении в примере является более ранний порядковый номер компоненты.

Таблица 1. Формирование матриц разложения по Методу I

Порог T	Бинарное изображение	Итерационный процесс формирования матриц разложения
$T \geq 7$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 6$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 5$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 3 & 0 & 0 \\ 1 & 2 & 2 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 0 & 1 & 2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$ $J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$

Продолжение Таблицы 1

$T \geq 4$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 2 & 0 & 4 & 0 & 0 \\ 2 & 3 & 3 & 1 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 1 & 2 & 3 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$ $J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 3$		$J_1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 3 & 1 & 5 & 0 & 0 \\ 3 & 4 & 4 & 2 & 1 \end{bmatrix}, J_2 = \begin{bmatrix} 2 & 3 & 4 & 1 & 1 \\ 0 & 2 & 2 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$
$T \geq 2$		$J_1 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 & 1 \\ 4 & 2 & 6 & 1 & 0 \\ 4 & 5 & 5 & 3 & 2 \end{bmatrix}.$
$T \geq 1$		$J_1 = \begin{bmatrix} 2 & 2 & 2 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$

В итоге будем иметь следующие матрицы:

$$J_1 = \begin{bmatrix} 2 & 2 & 2 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}, J_2 = \begin{bmatrix} 2 & 3 & 4 & 1 & 1 \\ 0 & 2 & 2 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

$$J_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (1)$$

Чтобы получить исходное изображение необходимо сложить эти матрицы:

$$I = J_1 + J_2 + J_3.$$

Теоретически каждая матрица соответствует определенному объекту интереса. Каждая из матриц, которая поглощает другую матрицу, обладает интересным свойством. Если некоторый объект высоты h положить на другой объект, то по рассматриваемому методу при разделении можно будет выделить этот объект с той же высотой h .

3.2. Яркостно-метрическое разложение изображения по топологическим признакам (Метод II). Рассмотрим теперь формирование J_1, J_2, \dots, J_q с использованием не только яркости, но и расстояния между пикселями. Под расстоянием между двумя пикселями будем понимать модуль разности между значениями соседних пикселей, т.е.:

$$d = |p_1 - p_2|,$$

где p_1, p_2 – два соседних пикселя. У каждого пикселя, как и в Методе I, может быть 4 соседа, т.е. рассматриваем только пиксели слева, сверху, справа и снизу от текущего.

Алгоритм формирования матриц при яркостно-метрическом разложении изображения по топологическим признакам состоит из следующих шагов:

Шаг 1. Рассчитывается список расстояний между соседними пикселями. Общее количество таких расстояний для изображения размером $m \times n$ равно $n(m-1) + m(n-1)$. По сути, получаем граф, где вершинами являются пиксели, а ребрами – расстояния между ними.

Шаг 2. Сортируется список расстояний по возрастанию значений.

Шаг 3. Сначала на исходном изображении I выделяются в компоненты все точки, расстояния между которыми $d \leq 0$, т.е. в группы объединяются точки одного цвета со значением 0. В этом случае исходное изображение не изменяется. Оно будет изменяться для параметра $d > 0$.

Шаг 4. На втором и следующих этапах объединяются компоненты, расстояние между которыми не больше d ($d = 1, 2, \dots, 255$). При поглощении компонентой других компонент их точки становятся цветом поглощающей компоненты. Очевидно, что расстояния между компонентами будут изменяться, т.к. меняется цвет компонент. В этом случае необходимо произвести перерасчет расстояний между компонентами, изменяя при этом и поддерживая в актуальном состоянии сортированный список расстояний. При каждом следующем шаге d анализируется текущее изображение с измененными значениями, после чего выбираются из списка расстояний обновленные связи между компонентами.

Шаг 5. Для каждого d ($d = 0, 1, 2, \dots, 255$) получаем изображение $I_{\leq d}$, которое является исходным для разложения по Методу I из пункта 3.1. Тем самым, для каждого d получим свой набор матриц разложения.

Покажем сказанное на примере (рисунок 2).

На рисунке 2 в левом столбце показан итерационный процесс формирования исходных изображений для их дальнейшего разложения по яркости. В первой строке разложение ничем не отличается от рассматриваемого выше по Методу I, т.к. исходное изображение не меняет значения точек. Для $d \leq 1$, $d \leq 2$ и $d \leq 3$ исходное изображение изменяется за счет слияния компонент, между которыми расстояние не больше d .

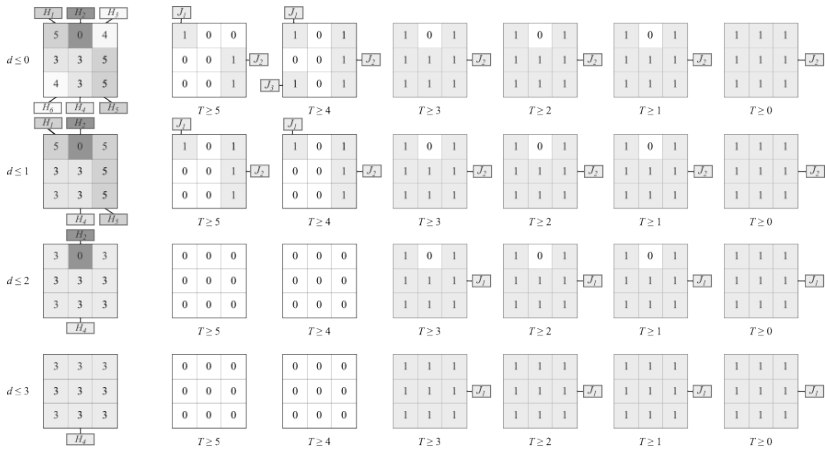


Рис. 2. Формирование матриц разложения по Методу II

В итоге для каждого значения d получим свой набор матриц разложения, а именно:

$$\text{для } d \leq 0: J_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 4 & 1 & 5 \\ 4 & 4 & 6 \\ 4 & 4 & 6 \end{bmatrix}, J_3 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix};$$

$$\text{для } d \leq 1: J_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, J_2 = \begin{bmatrix} 4 & 1 & 6 \\ 4 & 4 & 6 \\ 4 & 4 & 6 \end{bmatrix};$$

$$\text{для } d \leq 2: J_1 = \begin{bmatrix} 4 & 1 & 4 \\ 4 & 4 & 4 \\ 4 & 4 & 4 \end{bmatrix};$$

$$\text{для } d \leq 3: J_1 = \begin{bmatrix} 4 & 4 & 4 \\ 4 & 4 & 4 \\ 4 & 4 & 4 \end{bmatrix}.$$

Заметим, что при увеличении d исходное изображение становится более однотонным, что, в свою очередь, влияет на количество и структуру матриц разложения для каждого d .

При поглощении матриц здесь мы используем такой критерий, что при слиянии двух компонент приоритет на продолжение существования получает та компонента, которая имеет большее количество точек. Такой подход позволяет отслеживать более крупные по площади объекты.

Отличительной особенностью Метода II является формирование дополнительных матриц H_1, H_2, \dots, H_f . Они формируются по тому же самому принципу, что и матрицы J_1, J_2, \dots, J_q , но имеют характерную для себя структуру. В качестве изменяемого параметра используется не порог T , а расстояние d между компонентами. Каждая матрица H_k соответствует компоненте, которая была создана на первом этапе при $d \leq 0$. Значение ячейки в H_k показывает, сколько этапов d существовала эта компонента с номером k в этой ячейке, т.е. сколько сохранялся этот цвет в каждой ячейке.

Более устойчивые компоненты имеют достаточно большую наполняемость ячеек без нулевых элементов. Именно эти матрицы представляют особый интерес для анализа. Для примера из рисунка 2 матрицы H_1, H_2, \dots, H_6 имеют следующий вид:

$$H_1 = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, H_2 = \begin{bmatrix} 0 & 3 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, H_3 = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix},$$

$$H_4 = \begin{bmatrix} 2 & 1 & 2 \\ 4 & 4 & 2 \\ 3 & 4 & 2 \end{bmatrix}, H_5 = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 2 \\ 0 & 0 & 2 \end{bmatrix}, H_6 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix}.$$

3.3. Особенности представления объектов городской инфраструктуры. Городские объекты имеют вложенную структуру. Например, город состоит из кварталов, разделенных улицами, квартал включает домовые территории, каждая территория содержит объекты на ней. Если рассматривать более детально, то каждый объект включает в себя более мелкие объекты, например, трубы на зданиях.

Это соответствует стандартам детализации в геоинформатике, а также при 3D моделировании с большим количеством деталей.

Для объектов городской инфраструктуры будем применять концепцию из разделов 3.1. и 3.2. для описания вложенных элементов. При разложении изображения на матрицы получим объекты в виде областей интереса.

Матрицы разложения можно объединить по разным критериям. Это позволит выделить в отдельные слои объекты со схожей структурой, например, слои дорог, домов и деталей на этих домах.

Таким образом, иерархическая структура городских объектов хорошо сочетается с концепцией метода разложения по топологическим признакам. Однако существуют определенные проблемы, связанные с плавным переходом градиента на изображении. Для преодоления подобных проблем предлагается алгоритм для сегментации изображений по матрицам разложения.

4. Методология

4.1. Сегментация изображения на основе предлагаемой концепции. После разложения исходного изображения I на матрицы J_1, J_2, \dots, J_q либо по Методу I, либо по Методу II необходимо провести анализ этих матриц. Новое изображение I' формируется следующим образом. Для каждого пикселя в $I' = (p'_{ij})_{m \times n}$ вычисляется максимальное значение в соответствующей ячейке среди всех матриц J_1, J_2, \dots, J_q , т.е.:

$$I' = \begin{bmatrix} \max b_{11}^k & \max b_{12}^k & \dots & \max b_{1n}^k \\ \max b_{21}^k & \max b_{22}^k & \dots & \max b_{2n}^k \\ \dots & \dots & \dots & \dots \\ \max b_{m1}^k & \max b_{m2}^k & \dots & \max b_{mn}^k \end{bmatrix} \quad (k = 1, 2, \dots, q), \quad (2)$$

где b_{ij}^k ($i = 1, 2, \dots, m; j = 1, 2, \dots, n$) – значение элемента матрицы J_k .

Если рассмотреть полученные матрицы (1), то:

$$I' = \begin{bmatrix} 2 & 3 & 4 & 2 & 2 \\ 1 & 2 & 2 & 2 & 2 \\ 1 & 2 & 1 & 1 & 2 \\ 5 & 3 & 7 & 2 & 1 \\ 5 & 6 & 6 & 4 & 3 \end{bmatrix}.$$

В этом примере три нижние строки полностью совпадают с исходным изображением I и являются частью самой большой компоненты J_1 . Вызывает интерес анализ первых двух строк. Большинство пикселей имеют значение 2, и на этом фоне выделяется пара пикселей в первой строке со значением 3 и 4, которые соответствуют некоторому бугорку на исходном изображении.

Рассмотрим две компонента A и B в вертикальном разрезе изображения. Пусть компонента A поглощает компоненту B . Схематично покажем это на рисунках 3 и 4.

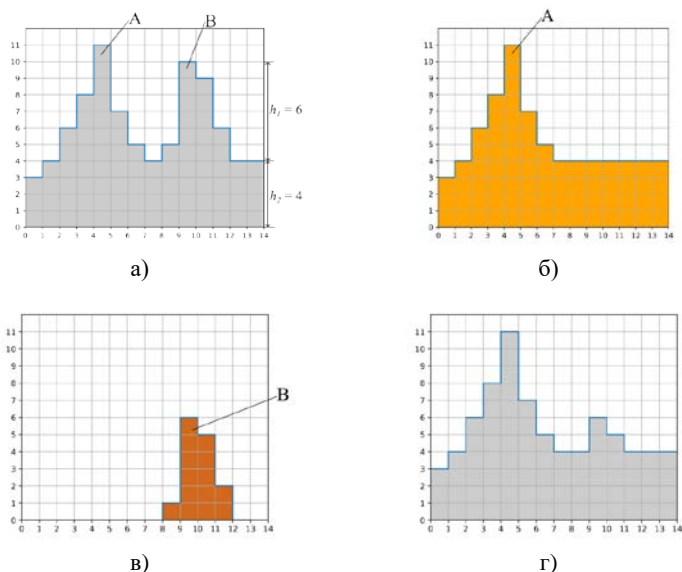


Рис. 3. Формирование изображения I' при $h_1 \geq h_2$: а) исходный вертикальный разрез изображения; б) выделение компоненты A ; в) выделение компоненты B ; г) результирующий вертикальный разрез изображения




Рис. 4. Формирование изображения I' при $h_1 < h_2$: а) исходный вертикальный разрез изображения; б) выделение компоненты A ; в) выделение компоненты B ; г) результирующий вертикальный разрез изображения

Рассмотрим возможные случаи формирования нового расположения компонент в зависимости от значений h_1 и h_2 , используя формулу (2):

1. $h_1 \geq h_2$. В этом случае в p_{ij} изначально было значение $h_1 + h_2$, где h_2 – это значение, при котором компонента A поглощает B , h_1 – это период существования компоненты B . После применения формулы (2) новым значением в этой точке будет h_1 .

2. $h_1 < h_2$. Новым значением для точки p'_{ij} будет h_2 , т.е. цвет фона.

Заметим из рисунка 4, что не только максимальная точка B принимает значение фона, но и все точки этой компоненты. Т.е. в новом изображении I' та область, которая соответствует значениям B , полностью принимает значение h_2 , т.е.:

$$p'_{ij} = h_2, \quad \text{если } (i, j) \in \text{координаты}(B).$$

Заметим теперь, что можно найти яркость g , на которой главная компонента будет всех включать в себя. Если $g \geq 128$, то по формуле (2) получим главную компоненту и фон g на всем изображении, т.к. высота каждой компоненты будет заведомо меньше, т.е. $h_1 \leq 127$.

Таким образом, можно сделать следующий вывод, что для отделения объектов друг от друга в рамках одной матрицы имеет смысл производить анализ не всех значений, а только эксклюзивных (т.е. за исключением поглощенных компонент) или инклюзивных (только поглощенных). Это может дать более точное определение поглощенного объекта и его контура.

4.2. Классификация пространственных объектов по топологическим признакам матриц разложения. Для классификации пространственных объектов также будем использовать матрицы разложения по топологическим особенностям. Для этого воспользуемся такими признаками, как баркоды.

Баркод определяется как множество пар значений из начала появления $birth_k$ компонент и их длин len_k :

$$Barcode = \left\{ (birth_k, len_k)_{k=1}^q \right\}. \quad (3)$$

Покажем, как можно получить баркодную характеристику из матриц разложения.

Пусть матрица разложения J_k состоит из элементов b_{ij}^k ($i = 1, 2, \dots, m; j = 1, 2, \dots, n; k \in \{1, 2, \dots, q\}$). Длина существования компоненты будет рассчитываться как максимальный элемент среди b_{ij}^k :

$$len_k = \max(b_{ij}^k). \quad (4)$$

Для того чтобы определить начало появления компоненты потребуется информация о вложенной структуре компонент, представленной в виде графа:

$$G = (V, E),$$

где V – множество компонент, E – множество ребер, обозначающих связи между компонентами.

После этого необходимо найти максимальное значение в матрице рассматриваемой компоненты J_k , которое находится в координатах (i_0, j_0) , и прибавить значения во всех вышестоящих родительских матрицах в ячейке с такими же координатами (i_0, j_0) :

$$birth_k = \begin{cases} \max(b_{ij}^k), & \text{если } J_k \text{ является корнем дерева} \\ \max(b_{ij}^k) + \sum_{u \in U} b_{i_0, j_0}^u, & \text{иначе} \end{cases}, \quad (5)$$

где U – множество всех индексов тех компонент, которые расположены выше компоненты J_k в графе G .

На основе выражений (4, 5) выразим баркод через свойства матриц разложения J_1, J_2, \dots, J_q :

$$Barcode = \left\{ \left(\max(b_{ij}^k) + \sum_{u \in U} b_{i_0, j_0}^u, \max(b_{ij}^k) \right)_{k=1}^n \right\}. \quad (6)$$

$(i = 1, 2, \dots, m; j = 1, 2, \dots, n).$

Для примера из таблицы 1 баркод будет состоять из матриц J_1, J_2, J_3 (1) и графически будет иметь вид (рисунок 5):




Рис. 5. Графическое отображение баркода для матриц разложения (1)

На рисунке 5 для каждой матрицы жирным шрифтом выделен максимальный элемент с координатами (i_0, j_0) , а в выделенных прямоугольником клетках показаны соответствующие ячейки в родительских матрицах на основе информации из вложенной структуры компонент. Эти значения позволяют вычислить начало появления каждой из компонент. Для примера имеем: $birth_1 = 7$, т.к. J_1 является корнем дерева, и поэтому находим только максимальный элемент в матрице этой компоненты, $birth_2 = 4 + 2 = 6$ и $birth_3 = 2 + 1 + 2 = 5$.

Такую характеристику будем использовать для классификации текстур пространственных объектов. Неплохие результаты в этом направлении нами были получены при исследовании топологических признаков для классификации объектов на изображениях с учетом их деформации и в сравнении с нейросетевыми подходами [29, 30].

Алгоритм классификации с использованием матриц разложения будет состоять из следующих шагов:

Шаг 1. Разложить исходное изображение I на матрицы J_1, J_2, \dots, J_q .

Шаг 2. Произвести сегментацию изображения на объекты интереса по алгоритму из п.4.1.


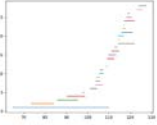

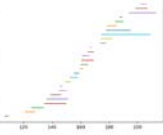

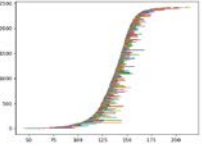
Шаг 3. Построить баркодную характеристику $Barcode_1, Barcode_2, \dots, Barcode_k$ для каждого объекта интереса. Заметим, что объект интереса может включать в себя не только одну, а несколько матриц разложения, образуя иерархическую структуру, т.е. $J = \{J_{\alpha_1}, J_{\alpha_2}, \dots, J_{\alpha_k}, \dots, J_{\alpha_q}\}$, где α_k – это номер матрицы разложения.

С учетом этого, совокупность объектов интереса разделяется на непересекающееся множество матриц из J_1, J_2, \dots, J_q . Они рассчитываются один раз и далее используются для анализа.

Шаг 4. Отнесение объекта интереса к определенному классу. Для этого заранее подготавливается набор шаблонов из пространственных объектов, соответствующих некоторому классу. Для каждого из них рассчитывается баркодная характеристика. Далее происходит сравнение баркодов путем наложения друг на друга и находится наиболее близкий класс, т.е. сравнение происходит в пространстве топологических признаков.

В качестве примера покажем баркоды нескольких пространственных объектов (таблица 2):

Таблица 2. Примеры пространственных объектов и их баркоды

Номер	Тип объекта	Изображение	Баркод
1	Односкатная крыша		
2	Двускатная крыша		
3	Дорога		

4.3. Геоинформационная технология для получения векторного изображения. Выше показано, что метод базируется на присоединении соседних точек, поэтому важно, чтобы в рамках одного объекта эмпирия стремилась к минимуму. В связи с этим, а также для подавления потенциальных шумов и искажений, в качестве предобработки проводится размытие по Гауссу.

Принцип векторизации с учетом баркодов исходит от утверждения, что каждая компонента поглощает конкретный объект на изображении, поэтому на первом этапе следует провести некий отбор, убрав наиболее неподходящие элементы.

Стоит заметить, что в случае обработки городских улиц следует использовать построение баркодов по расстоянию (Метод II). В случае простых изображений без лишних объектов можно применять более быструю обработку по яркости (Метод I).

Эксперименты показали, что после формирования баркода подавляющее большинство отрезков являются шумовыми, как, например, показано на рисунке 6. Также наиболее продолжительные компоненты могут образовывать большие зоны, которые покрывают почти все изображение, но не несут топологического смысла. В итоге получается следующее условие отбора:

$$N_{\min} < size < N_{\max} ,$$

где N_{\min} – минимально установленный процент размера компоненты относительно размера изображения, N_{\max} – максимально установленный процент размера компоненты относительно размера изображения, $size$ – размер компоненты относительно размера входного изображения.

Помимо геометрических параметров отбора присутствуют и топологические. В частности, имеет смысл ввести ограничение по трем характеристикам: глубина компоненты, время существования и время появления. Например, на космоснимках присутствуют тени, но путем установки начала появления компоненты их легко можно отсечь.




Рис. 6. Формирование компонент: а) исходное изображение, взятое по координатам * 55.794857, 37.497917 с увеличением 16^{\dagger} ; б) визуализация компонент

Второй этап предполагает использование баркодowego классификатора. Подробнее про технологию написано в [30]. Входной баркод сравнивается с набором эталонов, и выбирается тот класс, где соответствие выше. Таким образом, можно классифицировать не только спутниковые снимки, но и вообще любые объекты с разной топологией.

Для примера наглядно покажем процесс классификации, начиная с рисунка 7. После фильтрации получаем компоненты, показанные белым цветом.

* Здесь и в дальнейшем используется система координат WGS84 (EPSG:3857)

† Увеличение рассчитывается согласно формулам OpenStreetMap (https://wiki.openstreetmap.org/wiki/Zoom_levels)



Рис. 7. Все найденные компоненты, прошедшие отбор с параметрами size [0.0015, 10], minStart = 15, minLen = 10. Размер ядра размытия по Гауссу – 3^{\ddagger} . Параметры: size – диапазон размера относительно исходного изображения, т.е. площадь объекта должна быть от 0.0015% до 10% от площади всего изображения; minStart – минимальное значение начала существования компоненты, значение 15 позволяет отсечь тень; minLen – минимальная длина компоненты

Для классификации используем 3 класса: здания с двускатными и односкатными крышами, а также прочие объекты. После добавления одной компоненты получается результат, показанный на рисунке 8.




Рис. 8. Выделение зданий с двускатными крышами: а) после добавления обведенной компоненты; б) результат с отображением только классифицированных объектов

[‡] Все дальнейшие эксперименты проводились с аналогичными параметрами

Как видно, всего один эталон позволил выделить почти все двускатные крыши. Топологически дорога оказалась похожа на выбранный объект, поэтому добавим ее к прочим объектам, а также один дом с односкатной крышей к своему классу. Результат показан на рисунке 9.




Рис. 9. Классификация на различные типы объектов: а) отображение зданий с двускатными и односкатными крышами, а также прочих объектов; б) отображение только классов крыш

Дальнейшее добавление эталонов позволит полностью выделить и векторизовать нужные объекты, и при этом готовый классификатор будет работать на всех схожих по топологии изображениях. С учетом малого размера обучающей выборки это является огромным плюсом по сравнению с другими возможными подходами.

Отобранные баркоды хранят в себе набор пикселей. Их контур можно найти с помощью алгоритма жука. Сначала определяется начальная точка. Она может быть любой, главное, чтобы находилась на краю объекта. В реализованном алгоритме берется самая верхняя справа. Затем происходит процесс обхода: жук проверяет сначала левый пиксель, потом угловой слева, передний, угловой правый и правый. Потом перемещается на первый найденный пиксель. Таким образом, он все время поворачивает налево, совершая обход. Если же пиксель не найден, то есть жук зашел в тупик, то он возвращается, помечая пиксель как неликвидный. Процесс заканчивается, когда алгоритм вернется в начальную точку.

При формировании контура есть возможность его аппроксимировать путем сохранения только ключевых (угловых) точек. Например, у квадрата таких точек будет только 4. Определяются они путем проверки направлений: если жук повернул, то предыдущая точка – ключевая. Существуют и более продвинутые алгоритмы. Одним из них является алгоритм контурной аппроксимации Teh-Chin [31], который используется в библиотеке OpenCV для обработки изображений. Не смотря на это, в работе применяется простая аппроксимация отрезков, чтобы не создавать дополнительный фактор при оценке численных результатов найденных объектов. После получения первичного векторного представления объектов коррекция их формы в большинстве случаев реализуется вручную.

Зная координаты и проекцию (EPSG:3857), можно перевести пиксели контура в полигон и экспортировать его для последующей работы с ним в ГИС. Пример экспорта двух слоев показан на рисунке 10.

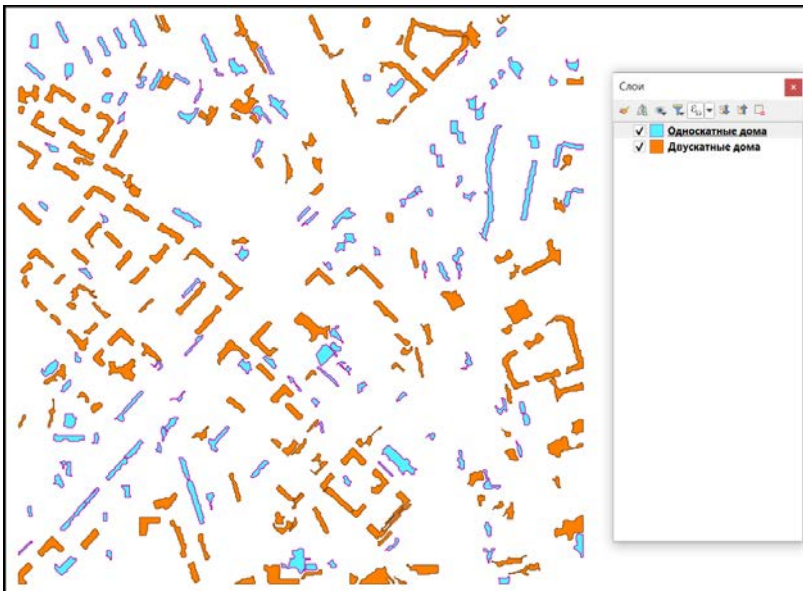


Рис. 10. Выходные данные, отображённые в ГИС QGIS

Общая схема предложенной геоинформационной технологии представлена на рисунке 11. Основными шагами являются: загрузка

спутникового снимка, вычисление и фильтрация матриц разложения, классификация объектов, а также выгрузка полученных векторных данных в geojson файл для чтения ГИС-программами.



Рис. 11. Общая схема геоинформационной технологии для векторизации областей интереса на спутниковом снимке с помощью матриц разложения. Пунктиром показаны шаги, выполняемые программой в фоновом режиме

5. Результаты экспериментальных исследований. Для оценки точности использовался классификатор с 80 эталонами и 3 классами: дома с односкатными крышами, двускатными, прочие объекты. Для оценки использовались только здания. Параметры были такие же, как и при обработке изображения 6. Также необходимо было подобрать аналог и провести аналогичную проверку на нем.

В последнее время многие статьи, решающие подобную задачу, основаны на использовании нейронных сетей с большими обучающими выборками. Вместо них было решено подобрать разработку, которая решала бы задачу векторизации максимально схожим образом с предлагаемым подходом. Таковым является инструмент Able R2V, способный работать с двумерными и трехмерными данными и векторизовать спутниковые снимки.

С помощью модуля на языке Python были получены векторные спутниковые снимки по координатам и их векторные слои. По вторым построена маска зданий для оценки точности. Для этого сначала на маске выделялись контуры всех зданий. Затем каждый базовый контур сравнивался с получившимся в результате тестирования. Векторизация для отдельного строения считалась успешной, если при наложении контур совпадал минимум на 85%. Это сделано, во-первых, чтобы нивелировать возможные расхождения между растром и вектором, а во-вторых, потому что поперечная зона может быть спорной.

При успешном выделении здания к счетчику добавляется единица, умноженная на отношение площади этого здания к сумме всех площадей – чем больше здание, тем больше вклада в результат.

После сравнения из итогового показателя вычитается отношение суммы всех лишних ложных полигонов к площади снимка.

Результаты проверки приведены в таблице 3. Исходные изображения показаны на рисунке 12.

Можно представить и более обширную выборку, однако, это имеет мало смысла, так как топологически схожие объекты останутся схожими вне зависимости от смежных данных.

Таблица 3. Результаты тестирования для оценки точности векторизации объектов на снимках

Номер изображения	Долгота	Широта	Предложенный метод, точность, %	R2V, точность, %
1	37,613656	127,019822	82	67
2	47,917771	106,902695	81	59
3	53,210474	50,224138	78	75
4	53,229711	50,275348	74	73
5	55,740047	37,632779	87	60
6	55,78629	37,573403	78	72
7	55,813148	37,570192	71	75
8	55,824066	37,58251	69	72
9	55,610299	37,705359	83	71
10	56,138963	40,39506	77	76
11	56,144008	40,423329	84	74
12	56,172059	40,482485	90	79
13	56,126108	40,357699	89	73
14	55,781155	37,474521	82	75
15	55,777904	37,495079	76	77
16	55,781020	37,518276	92	75
17	55,780875	37,551987	73	67
18	55,817086	37,591099	86	80
19	55,823973	37,564358	75	73
20	55,834031	37,56841	86	84
Итого			81	73



Рис. 12. Тестовые изображения (нумерация построчная слева направо)

Единственное, что может негативно повлиять на результат, это ложные срабатывания у объектов со схожей топологией, об этом и говорит средний результат в 81%. Наихудший процент (61) был получен на изображении № 8. Его обработанный результат показан на рисунке 13.

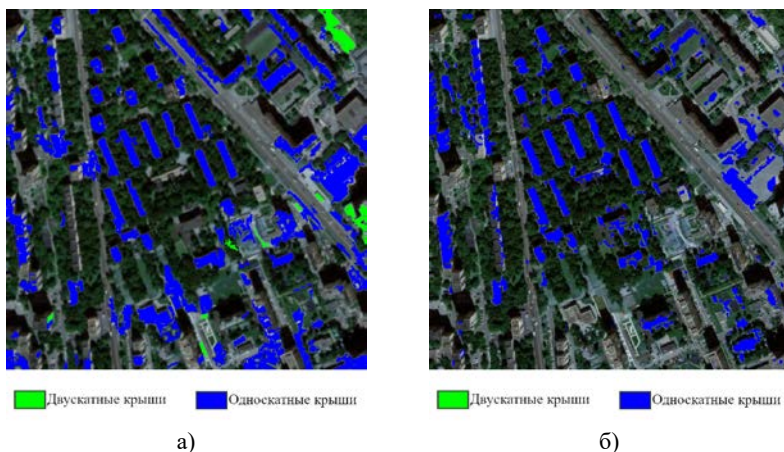


Рис. 13. Результаты классификации изображения №8: а) предложенный метод; б) R2V

Для баркодов проблемы вызывают два фактора: во-первых, если посмотреть на дома слева, то можно увидеть ребра, из-за которых отдельные компоненты не соединяются, и не образуется общего баркода крыши. Вторая – у дорог и некоторых других поверхностей схожий баркод с представленными эталонами. Поэтому следует использовать дополнительные топологические параметры при сравнении.

Программа R2V ориентируется на цвет, после векторизации использовалась фильтрация слишком маленьких объектов. Как видно, неровная текстура некоторых зданий не позволила получить цельные контуры, вместо этого алгоритм выявил множество отдельных полигонов, которые отсеялись. Также заметно несколько ложных срабатываний из-за того, что эти области имеют схожий с объектами цвет и топологию.

Одним из наилучших результатов у предложенного метода (90%) был получен на снимке №12 и отражен на рисунке 14. Почти все здания на исходном изображении четко выделены и не сливаются с фоном, что позволяет получить точный баркод. Хотя, стоит заметить, кусочек дороги ошибочно классифицировался как крыша. Такая же картина прослеживается и на снимках 16 (92%) и 13 (89%).

Аналог также хорошо показал себя, однако некоторые здания остались невыделенными. У него остаются все те же проблемы с ликвидным цветом и параметрами фильтрации, что были описаны выше.

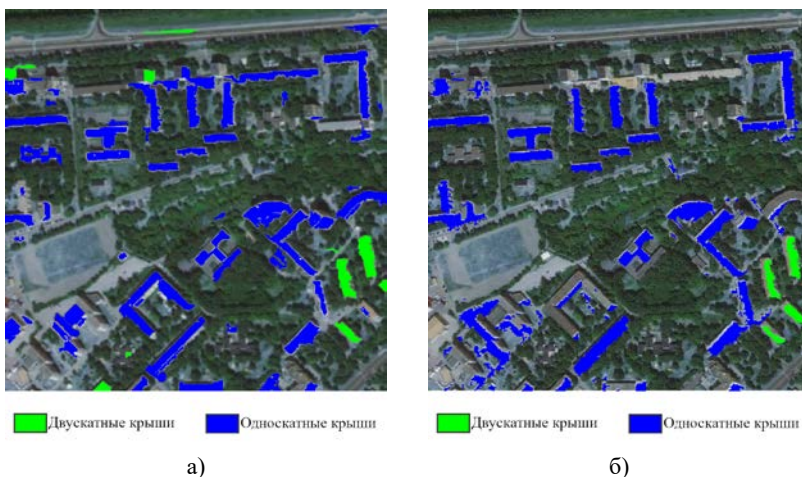


Рис. 14. Результаты классификации изображения №12: а) предложенный метод; б) R2V

Сравнение показало, что баркоды, строясь по яркости, почти от нее не зависят, что доказывает состоятельность теории как базы для совершенно нового подхода сегментации изображений.

Что касается результатов сравнения, то, безусловно, можно добиться и среднего показателя в 90%, однако это затруднено из-за пока вышеупомянутых проблем, а также еще одного фактора: деградации скорости выполнения при увеличении эталонов (в том числе для решения этой проблемы и была проведена начальная фильтрация).

Отдельно следует сказать про затрачиваемое время на работу. У программ, подобных R2V, при анализе каждого снимка требуется вручную задать пороги бинаризации, по обстоятельствам выбрать алгоритм фильтрации, а потом кропотливо выравнивать полигоны, тогда как предлагаемая разработка лишена первых двух требований и частично третьего. Использование матриц разложения позволяет получить более точные выходные полигоны, что делает работу продуктивнее.

6. Заключение. В статье разработан метод для получения из спутниковых снимков векторных данных, распределенных по разным слоям ГИС. Предложенный метод включает комплексное решение для векторизации пространственных объектов и содержит основные этапы в виде сегментации, классификации и аппроксимации областей интереса на изображении. Основная часть методологии базируется на

предложенной концепции разложения растрового изображения по топологическим особенностям.

На основе концепции разработан алгоритм сегментации, который позволяет выделить объекты интереса с устойчивыми топологическими признаками и избежать настраивания порога бинаризации, что свойственно многим методам. Разложение изображения позволяет также получить в качестве признаков матрицы специального типа для классификации сегментированных объектов. Выбрано несколько типов зданий для их классификации и дальнейшего распределения по слоям в векторном виде.

Проведенные эксперименты реальных данных показали высокие результаты (81% в режиме автоматической векторизации против 73% у полуавтоматического аналога). В качестве ГИС, в которую загружались обработанные данные в векторном виде, использованы инструменты QGIS, что позволяет интегрировать данные с существующей ГИС организации. При практическом использовании предложенного метода планируется расширить тематические слои, что даст возможность ускорить процесс перевода спутниковых снимков в векторный формат.

Представлен совершенно новый тип just-in-time классификатора, который работает с малым числом эталонов и выдает достойный результат. Сама разработка и тестовые данные доступны по ссылке: <https://github.com/Noremos/SatelliteVectorization>.

Литература

1. Miroshnichenko S.Yu., Titov V.S., Dremov E.N., Mosin S.A. Hough Transform Application to Digitize Rectangular Spatial Objects on Aerospace Imagery // *Trudy SPIIRAN*. 2018. vol. 61. pp. 172–196.
2. Kurlin V., Muszynski G. A Persistence-Based Approach to Automatic Detection of Line Segments in Images // *Proc. CTIC: Comp. Topology in Image Context*. 2019. pp. 137–150.
3. Edelsbrunner H., Harer J. *Computational topology. An introduction*. 2010.
4. Еремеев С.В., Абакумов А.В., Андрианов Д.Е., Титов Д.В. Метод разложения изображения по топологическим признакам // *Компьютерная оптика*. 2022. Т. 46. № 6. С. 939–947.
5. Bessmeltsev M., Solomon J. Vectorization of Line Drawings via Polyvector Fields // *ACM Transactions on Graphics*. 2019. vol. 38. no. 1. pp. 1–12.
6. Бобырь М.В., Архипов А.Е., Горбачев С.В., Цао Ц., Бхаттачарья С. Нечеткологические методы в задаче детектирования границ объектов // *Информатика и автоматизация*. 2022. Т. 21. № 2. С. 376–404.
7. Von Gioi R.G., Jakubowicz J., Morel J.M., Randall G. LSD: A Fast Line Segment Detector with a False Detection Control // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2010. vol. 32. no. 4. pp. 722–732.
8. Akinlar C., Topal C. Edlines: A Real-Time Line Segment Detector with a False Detection Control // *Pattern Recognition Letters*. 2011. vol. 32. no. 13. pp. 1633–1642.

9. Новоторцев Л.В., Волобой А.Г. Обнаружение и трехмерная реконструкция строений по аэрофотоснимкам // Программирование. 2019. № 6. С. 13–22.
10. Чернов А.В., Чушнев Н.В. Автоматическое распознавание контуров зданий на картографических изображениях // Компьютерная оптика. 2007. Т. 31. № 4. С. 101–103.
11. Кудряшов А.П., Соловьёв И.В. Выделение объектов на топографическом плане для реконструкции сцены городского пространства // Программная инженерия. 2019. Т. 10. № 11–12. С. 464–470.
12. Москаленко С.В., Гатчин Ю.А. Помехоустойчивый волновой алгоритм векторизации линейных растровых объектов // Вестник компьютерных и информационных технологий. 2009. № 5. С. 16–21.
13. Стержанов М.В. Быстрый алгоритм векторизации бинарных штриховых изображений // Доклады БГУИР. 2010. Т. 50. № 4. С. 88–94.
14. Костюк Ю.Л., Кон А.Б., Новиков Ю.Л. Алгоритмы векторизации цветных растровых изображений на основе триангуляции и их реализация // Вестник Томского Государственного Университета. 2003. № 280. С. 275–280.
15. Местецкий Л.М. Скелетизация многосвязной многоугольной фигуры на основе дерева смежности ее границы // Сибирский журнал вычислительной математики. 2006. Т. 9. № 3. С. 299–314.
16. Залесский Б.А. Комбинаторный алгоритм выделения контуров объектов на цифровых изображениях // Информатика. 2013. № 3. С. 13–20.
17. Фраленко В.П. Методы текстурного анализа изображений, обработка данных дистанционного зондирования Земли // Программные системы: теория и приложения. 2014. Т. 5. № 4. С. 19–39.
18. Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. Классификация космоснимков Sentinel-2 Байкальской природной территории // Компьютерная оптика. 2022. Т. 46. № 1. С. 90–96.
19. Yan K., Xu Y., Chen H. Building Boundary Vectorization from Satellite Images Using Generative Adversarial Networks // The International Conference on Image, Vision and Intelligent Systems (ICIVIS 2021). Lecture Notes in Electrical Engineering, 2022. vol. 813. pp. 671–678.
20. Alsabhan W., Alotaiby T., Dudin B. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net // Computational Intelligence and Neuroscience. 2022. vol. 2022.
21. Temenos A., Temenos N., Doulamis A., Doulamis N. On the Exploration of Automatic Building Extraction from RGB Satellite Images Using Deep Learning Architectures Based on U-Net // Technologies. 2022. vol. 10.
22. Guo M, Liu H, Xu Y, Huang Y. Building Extraction Based on U-Net with an Attention Block and Multiple Losses // Remote Sensing. 2020. vol. 12. no. 9.
23. Wei S., Ji S. Graph Convolutional Networks for the Automated Production of Building Vector Maps From Aerial Images // IEEE Transactions on Geoscience and Remote Sensing. 2022. vol. 60. pp. 1–11.
24. Xu Y., Jin S., Chen Z., Xie X., Hu S., Xie Z. Application of a Graph Convolutional Network with Visual and Semantic Features to Classify Urban Scenes // International Journal of Geographical Information Science. 2022. vol. 36. pp. 1–26.
25. Chartock E., LaRow W., Singh V. Extraction of Building Footprints from Satellite Imagery // Stanford University Report. 2017.
26. Hensel S., Goebels S., Kada M. Building Roof Vectorization with PPGNET // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLVI-4/W4-2021. 2021. pp. 85–90.
27. Форгуна-Сервантес Х.М., Рамирес-Торрес М.Т., Мартинес-Карранса Х., Мургуя-Ибарра Х.С., Мехия-Карлос М. Обнаружение объектов в

- аэронавигации с использованием вейвлет-преобразования и сверточных нейронных сетей: первый подход // Труды института системного программирования РАН. 2021. Т. 33. № 2. С. 149–162.
28. Нежевенко Е.С., Феоктистов А.С., Дашевский О.Ю. Нейросетевая классификация гиперспектральных изображений на основе преобразования Гильберта – Хуанга // Автометрия. 2017. Т. 53. № 2. С. 79–85.
 29. Еремеев С.В., Абакумов А.В. Программный комплекс для обнаружения и классификации природных объектов на основе топологического анализа // Программные продукты и системы. 2021. Т. 34. № 1. С. 201–208.
 30. Еремеев С.В., Абакумов А.В. Классификация объектов на изображениях с учетом искажений на основе двухэтапного топологического анализа // Научно-технический вестник информационных технологий, механики и оптики. 2022. Т. 22. № 1. С. 82–92.
 31. Teh C.-H., Chin R.T. On the detection of dominant points on digital curves // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1989. vol. 11. no. 8. pp. 859–872.

Еремеев Сергей Владимирович — канд. техн. наук, доцент кафедры, кафедра информационных систем факультета информационных технологий, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 101. sv-eremeev@yandex.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7122.

Абакумов Артём Владимирович — аспирант, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 10. artem210966@yandex.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7112.

Андрианов Дмитрий Евгеньевич — д-р техн. наук, доцент, заведующий кафедрой, кафедра информационных систем факультета информационных технологий, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых». Область научных интересов: обработка пространственных данных, геоинформационные системы, топологический анализ данных. Число научных публикаций — 102. AndrianovDE@inbox.ru; улица Орловская, 23, 602264, Муром, Россия; р.т.: 8(492)347-7112.

Ширабакина Тамара Александровна — канд. техн. наук, профессор кафедры, кафедра вычислительной техники факультета фундаментальной и прикладной информатики, Юго-Западный государственный университет. Область научных интересов: обработка изображений, системы технического зрения. Число научных публикаций — 89. tas_06@mail.ru; улица 50 лет Октября, 94, 305040, Курск, Россия; р.т.: +7(471)222-2665.

Поддержка исследований. Исследование выполнено в рамках Программы развития ЯРГУ, проект № П2-ГМЗ-2021.

S. EREMEEV, A. ABAKUMOV, D. ANDRIANOV, T. SHIRABAKINA
**VECTORIZATION METHOD OF SATELLITE IMAGES BASED ON
THEIR DECOMPOSITION BY TOPOLOGICAL FEATURES**

Eremeev S., Abakumov A., Andrianov D., Shirabakina T. Vectorization Method of Satellite Images Based on Their Decomposition by Topological Features.

Abstract. Vectorization of objects from an image is necessary in many areas. The existing methods of vectorization of satellite images do not provide the necessary quality of automation. Therefore, manual labor is required in this area, but the volume of incoming information usually exceeds the processing speed. New approaches are needed to solve such problems. The method of vectorization of objects in images using image decomposition into topological features is proposed in the article. It splits the image into separate related structures and relies on them for further work. As a result, already at this stage, the image is divided into a tree-like structure. This method is unique in its way of working and is fundamentally different from traditional methods of vectorization of images. Most methods work using threshold binarization, and the main task for them is to select a threshold coefficient. The main problem is the situation when there are several objects in the image that require a different threshold. The method departs from direct work with the brightness characteristic in the direction of analyzing the topological structure of each object. The proposed method has a correct mathematical description based on algebraic topology. On the basis of the method a geoinformation technology has been developed for automatic vectorization of raster images in order to search for objects located on it. Testing was carried out on satellite images from different scales. The developed method was compared with a special tool for vectorization R2V and showed a higher average accuracy. The average percentage of automatic vectorization of the proposed method was 81%, and the semi-automatic vectorizing module R2V was 73%.

Keywords: spatial data, image decomposition, topological features, vectorization.

References

1. Miroshnichenko S.Yu., Titov V.S., Dremov E.N., Mosin S.A. Hough Transform Application to Digitize Rectangular Spatial Objects on Aerospace Imagery. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2018. vol. 61. pp. 172–196.
2. Kurlin V., Muszynski G. A Persistence-Based Approach to Automatic Detection of Line Segments in Images. *Proc. CTIC: Comp. Topology in Image Context*. 2019. pp. 137–150.
3. Edelsbrunner H., Harer J. *Computational topology. An introduction*. 2010.
4. Eremeev S.V., Abakumov A.V., Andrianov D.E., Titov D.V. [Image Decomposition Method by Topological Features]. *Komp'yuternaja optika – Computer Optics*. 2022. vol. 46. no. 6. pp. 939–947. (In Russ.).
5. Bessmeltsev M., Solomon J. Vectorization of Line Drawings via Polyvector Fields. *ACM Transactions on Graphics*. 2019. vol. 38. no. 1. pp. 1–12.
6. Bobyr M.V., Arhipov A.E., Gorbachev S.V., Cao C., Bhattachar'ja S. [Fuzzy Logic Approaches in the Task of Object Edge Detection]. *Informatika i avtomatizacija – Informatics and Automation*. 2022. vol. 21. no. 2. pp. 376–404. (In Russ.).
7. Von Gioi R.G., Jakubowicz J., Morel J.M., Randall G. LSD: A Fast Line Segment Detector with a False Detection Control. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2010. vol. 32. no. 4. pp. 722–732.

8. Akinlar C., Topal C. Edlines: A Real-Time Line Segment Detector with a False Detection Control. *Pattern Recognition Letters*. 2011. vol. 32. no. 13. pp. 1633–1642.
9. Novotortsev L.V., Voloboy A.G. Detection and 3D Reconstruction of Buildings from Aerial Images. *Programming and Computer Software*. 2019. vol. 45. no. 6. pp. 311–318.
10. Chernov A.V., Chupshev N.V. [Automatic Recognition of Building Contours on Cartographic Images]. *Komp'yuternaja optika – Computer Optics*. 2007. vol. 31. no. 4. pp. 101–103. (In Russ.).
11. Kudryashov A.P., Solovyev I.V. [Detection of Objects on the Topographical Map for Reconstruction of the Scene of Urban Space]. *Programmhnaja inzhenerija – Software Engineering*. 2019. vol. 10. no. 11-12. pp. 464–470. (In Russ.).
12. Moskalenko S.V., Gatchin Y.A. [Noise Stayable Wave Method of Raster Line Vectorization]. *Vestnik komp'yuternyh i informacionnyh tehnologij – Herald of Computer and Information Technologies*. 2009. no. 5. pp. 16–21. (In Russ.).
13. Sterjanov M.V. [Fast Vectorization Algorithm of Line Image Drawings]. *Doklady BGUIR*. 2010. vol. 50. no. 4. pp. 88–94. (In Russ.).
14. Kostyuk Y.L., Kon A.B., Novikov Y.L. [Algorithms for Vectorization of a MultiColor Raster Image Based on Triangulation and Their Realization]. *Vestnik Tomskogo Gosudarstvennogo Universiteta – Tomsk State University Journal*. 2003. no. 280. pp. 275–280. (In Russ.).
15. Mestetskiy L.M. [Skeletonization of a Multiply-Connected Polygonal Domain Based on Its Boundary Adjacent Tree]. *Sibirskij zhurnal vychislitel'noj matematiki – Siberian J. of Numer. Mathematics*. 2006. vol. 9. no. 3. pp. 299–314. (In Russ.).
16. Zalesky B.A. [Combinatorial Algorithm for Object Contours Detection of Digital Images]. *Informatika – Informatics*. 2013. no. 3. pp. 13–20. (In Russ.).
17. Fralenko V.P. [Methods of Image Texture Analysis, Earth Remote Sensing Data Processing]. *Programmnyye sistemy: teorija i prilozhenija – Program Systems: Theory and Applications*. 2014. vol. 5. no. 4. pp. 19–39. (In Russ.).
18. Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Y.V. [Classification of Sentinel-2 satellite images of the Baikal Natural Territory]. *Komp'yuternaja optika – Computer Optics*. 2022. vol. 46. no. 1. pp. 90-96. (In Russ.).
19. Yan K., Xu Y., Chen H. Building Boundary Vectorization from Satellite Images Using Generative Adversarial Networks. *The International Conference on Image, Vision and Intelligent Systems (ICIVIS 2021)*. *Lecture Notes in Electrical Engineering*. 2022. vol. 813. pp. 671–678.
20. Alsabhan W., Alotaiby T., Dudin B. Detecting Buildings and Nonbuildings from Satellite Images Using U-Net. *Computational Intelligence and Neuroscience*. 2022. vol. 2022.
21. Temenos A., Temenos N., Doulamis A., Doulamis N. On the Exploration of Automatic Building Extraction from RGB Satellite Images Using Deep Learning Architectures Based on U-Net. *Technologies*. 2022. vol. 10.
22. Guo M, Liu H, Xu Y, Huang Y. Building Extraction Based on U-Net with an Attention Block and Multiple Losses. *Remote Sensing*. 2020. vol. 12. no. 9.
23. Wei S., Ji S. Graph Convolutional Networks for the Automated Production of Building Vector Maps from Aerial Images. *IEEE Transactions on Geoscience and Remote Sensing*. 2022. vol. 60. pp. 1–11.
24. Xu Y., Jin S., Chen Z., Xie X., Hu S., Xie Z. Application of a Graph Convolutional Network with Visual and Semantic Features to Classify Urban Scenes. *International Journal of Geographical Information Science*. 2022. vol. 36. pp. 1–26.
25. Chartock E., LaRow W., Singh V. Extraction of Building Footprints from Satellite Imagery. *Stanford University Report*. 2017.

26. Hensel S., Goebbels S., Kada M. Building Roof Vectorization with PPGNET. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLVI-4/W4-2021. 2021. pp. 85–90.
27. Fortuna-Cervantes J.M., Ramirez-Torres M.T., Martinez-Carranza J., Murguia-Ibarra J.S., Mejia-Carlos M. [Object Detection in Aerial Navigation Using Wavelet Transform and Convolutional Neural Networks: a First Approach]. Trudy instituta sistemnogo programirovaniya RAN – Proceedings of ISP RAS. 2021. vol. 33. no. 2. pp. 149–162. (In Russ.).
28. Nezhevenko E.S., Feoktistov A.S., Dashevskii O.Y. Neural Network Classification of Hyperspectral Images on the Basis of the Hilbert – Huang Transform. Optoelectronics, Instrumentation and Data Processing. 2017. vol. 53. no. 2. pp. 165–170.
29. Ereemeev S.V., Abakumov A.V. [Software Complex for Detection and Classification of Natural Objects Based on Topological Analysis]. Programmnye produkty i sistemy – Software & Systems. 2021. vol. 34. no. 1. pp. 201–208. (In Russ.).
30. Ereemeev S.V., Abakumov A.V. [Classification of Objects in Images with Distortions Based on a Two-Stage Topological Analysis]. Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2022. vol. 22. no. 1. pp. 82–92. (In Russ.).
31. Teh C.-H., Chin R.T. On the detection of dominant points on digital curves. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1989. vol. 11. no. 8. pp. 859–872.

Ereemeev Sergey — Ph.D., Associate professor of the department, Department of information systems, faculty of information technology, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geographic information systems and topological data analysis. The number of publications — 101. sv-eremeev@yandex.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7122.

Abakumov Artyom — Postgraduate student, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geoinformation systems and topological data analysis. The number of publications — 10. artem210966@yandex.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7112.

Andrianov Dmitry — Ph.D., Dr.Sci., Associate Professor, Head of the department, Department of information systems, faculty of information technology, Murom Institute (branch) of Vladimir State University. Research interests: spatial data processing, geographic information systems and topological data analysis. The number of publications — 102. AndrianovDE@inbox.ru; 23, Orlovskaya St., 602264, Murom, Russia; office phone: 8(492)347-7112.

Shirabakina Tamara — Ph.D., Professor of the department, Department of computer engineering, faculty of fundamental and applied informatics, Southwest State University. Research interests: image processing and computer vision systems. The number of publications — 89. tas_06@mail.ru; 94, 50 let Oktyabrya St., 305040, Kursk, Russia; office phone: +7(471)222-2665.

Acknowledgements. The reported study was funded by the YSU Programme (the research project No. P2-GM3-2021).