



## СИСТЕМНЫЙ АНАЛИЗ

УДК 351.78:004.4

DOI: 10.31799/2077-5687-2026-2-3-18

### АНАЛИЗ РАЗМЕЩЕНИЯ СРЕДСТВ ВИДЕОНАБЛЮДЕНИЯ В ПРЕДЕЛАХ ГОРОДСКОЙ АГЛОМЕРАЦИИ

**Ю. А. Журавлева, С. А. Андронов**

Санкт-Петербургский государственный университет аэрокосмического приборостроения

*В статье представлена реализация комплексного анализа пространственного размещения видеокамер в пределах г. Санкт-Петербург с использованием low-code платформы Loginom. Актуальность работы обусловлена необходимостью объективной оценки эффективности систем видеонаблюдения мегаполиса на основе данных о размещении камер. Выполнен сравнительный анализ пяти методов кластеризации (DBSCAN, k-means, g-means, SOM, EM-кластеризация) с оценкой качества по внутренним и внешним метрикам. На основе выбранного метода вычислены центроиды кластеров, проведён пространственный анализ размещения камер в Центральном (туристическом) и Приморском (спальном) районах, выявлены количественные различия в плотности и компактности группировки видеокамер. Предложено использование центроидов кластеров для размещения единых центров мониторинга.*

*Ключевые слова:* кластеризация, анализ пространственных данных, видеонаблюдение, Loginom, центроиды кластеров, пространственный анализ.

#### **Для цитирования:**

*Журавлева, Ю. А. Анализ размещения средств видеонаблюдения в пределах городской агломерации / Ю. А. Журавлева, С. А. Андронов // Системный анализ и логистика. – 2026. – № 2(50). – с. 3-18. DOI: 10.31799/2077-5687-2026-2-3-18.*

### ANALYSIS OF VIDEO SURVEILLANCE PLACEMENT WITHIN THE CITY AGGLOMERATION

**J. A. Zhuravleva, S. A. Andronov**

St. Petersburg State University of Aerospace Instrumentation

*The article presents the implementation of a comprehensive analysis of the spatial distribution of video cameras using the Loginom low-code platform. The relevance of the work is due to the need for an objective assessment of the effectiveness of video surveillance systems in a megacity based on data on the placement of cameras. A comparative analysis of five clustering methods (DBSCAN, k-means, g-means, SOM, EM-clustering) is performed using internal and external quality metrics. Based on the reference k-means method, cluster centroids are calculated, and a spatial analysis of camera placement is carried out for the Central (tourist) and Primorsky (residential) districts, revealing quantitative differences in camera density and clustering compactness. The use of centroids is proposed as reference points for the placement of unified monitoring centers.*

*Keywords:* clustering, spatial data analysis, video surveillance, Loginom, cluster centroids, and spatial analysis.

#### **For citation:**

*Zhuravleva, Yu. A. Analysis of video surveillance placement within the city agglomeration / Yu. A. Zhuravleva, S. A. Andronov // System analysis and logistics. – 2026. – № 2(50). – p. 3-18. DOI: 10.31799/2077-5687-2026-2-3-18.*

#### **Введение**

Растущая тенденция урбанизации требует формирования концепции «умных городов», одной из основных составляющих которой является безопасность общественных мест, находящихся в ведении города. Система видеонаблюдения в общественных местах должна способствовать личной безопасности граждан, детей и участников дорожного движения, снижению уровня преступности и повышению эффективности работы общественных служб.

Эффективность системы видеонаблюдения мегаполиса напрямую зависит от пространственного распределения камер видеонаблюдения. Для объективной оценки и выявления зон с избыточной или недостаточной плотностью покрытия видеокамер в данной работе используется анализ пространственных данных, основанный на методах



кластеризации.

Вопрос оптимального размещения камер видеонаблюдения активно исследуется зарубежными авторами в контексте повышения эффективности систем «безопасного города». Значительное число работ посвящено оценке влияния видеонаблюдения на уровень преступности. В масштабном обзоре The Campbell Collaboration [1] было показано, что камеры оказывают незначительное влияние на общий уровень преступности, демонстрируя эффективность преимущественно на автостоянках и в отношении преступлений, связанных с транспортными средствами. Шведское исследование [2] подтвердило, что установка камер способствует снижению преступности лишь в небольшой степени (на 16%) в зонах с камерами по сравнению с контрольными зонами, причём наилучший результат был достигнут на автостоянках (51%). Аналогичные выводы были получены в Испании [3] и США [4], где не было зафиксировано значимого снижения насильственных преступлений, а в ряде случаев наблюдался эффект «перемещения» преступности в соседние районы.

В то же время исследования подчёркивают, что ключевым фактором является не столько количество камер, сколько обоснованность их размещения. Работы, выполненные в Южной Корее [5], показали, что научно обоснованное размещение камер позволяет добиться значительного снижения грабежей и краж (до 47,4%) без эффекта перемещения. Тайваньское исследование [6] выявило, что видеонаблюдение снижает количество грабежей, но не влияет на другие преступления против собственности. Эти результаты указывают на необходимость применения пространственного анализа для оптимизации конфигурации систем видеонаблюдения.

В российской практике аналогичные выводы были получены на основе анализа системы видеонаблюдения Москвы [7]. Авторы показали, что высокая плотность камер не гарантирует снижения преступности, а их установка без предварительного анализа неэффективна. В частности, количество камер в местах массового скопления людей не коррелирует ни с численностью населения, ни с площадью районов, ни с уровнем преступности, что свидетельствует о недостаточно обоснованной политике размещения. В работе [8] на примере сетевой компании также показано, что методы кластеризации (в частности, k-means и DBSCAN) позволяют эффективно выявлять зоны концентрации объектов и определять оптимальные точки размещения инфраструктуры, что подтверждает целесообразность использования подобного подхода для анализа систем видеонаблюдения. Данное заключение актуализирует задачу развития методов пространственного анализа, позволяющих объективно оценивать существующую структуру размещения камер и выявлять зоны избыточной или недостаточной плотности покрытия.

Таким образом, результаты кластеризации позволяют не только выявить зоны концентрации камер, но и определить потенциальные центры управления видеонаблюдением. Основными функциями центров кластеров видеонаблюдения являются:

- объединение множества камер видеонаблюдения в единую сеть, обеспечивая бесперебойную работу;
- мониторинг общественных мест, парков, улиц и объектов инфраструктуры;
- обнаружение преступлений, аварий и правонарушений для оперативного вызова экстренных служб;
- использование интеллектуальных функций (распознавание лиц, номеров автомобилей) для поиска правонарушителей.

Сказанное особенно важно для создания единой городской системы мониторинга, которая объединяет разрозненные видеопотоки, обеспечивает оперативное реагирование на правонарушения, управление трафиком и хранение архивов для расследований. В работе показано, как на основе кластерного анализа расположения средств видеонаблюдения могут быть выделены наилучшие точки размещения таких центров.



### **Постановка задачи**

Методы кластерного анализа реализованы во многих программных системах, связанных с анализом данных. В первую очередь это библиотека Python для анализа данных и машинного обучения Scikit-learn [9], а также аналитические low-code платформы, таких как Knime [10], Loginom [11] и пр. Предлагаемое в статье исследование было выполнено в бесплатной отечественной десктопной версии программы Loginom Community, в арсенале которой имеется ряд методов кластеризации: обработчик «Кластеризация» (в вариантах k-means, g-means (разновидность k-средних)), ЕМ-кластеризация, Самоорганизующаяся сеть.

В реализации цели исследования в среде вышеназванной аналитической платформы потребовалось разработать сценарии кластеризации для оценки пространственного распределения видеокамер по административным районам Санкт-Петербурга, провести сравнительный анализ вышеназванных пяти методов кластеризации с использованием внутренних и внешних метрик качества. Результаты кластеризации на основе наилучшего метода предполагается использовать для анализа размещения видеокамер, вычислив центроиды кластеров и сравнив пространственные характеристики (внутрикластерные расстояния, расстояния между центроидами, плотность камер) для Центрального (туристического) и Приморского (спального) районов Санкт-Петербурга. Полученные центроиды предлагается использовать как опорные точки для размещения единых центров мониторинга. Для наглядности необходимо выполнить визуализацию найденных кластеров на карте города, а также показать расположение потенциальных центров мониторинга.

### **Используемые методы кластеризации**

Под кластеризацией (сегментацией) понимается группировка объектов (наблюдений, событий) на основе данных, описывающих свойства объектов. При этом объекты внутри кластера должны быть похожими друг на друга и отличаться от объектов, попавших в другие кластеры [12]. В данном исследовании объектами кластеризации выступают видеокамеры, установленные на территории районов Санкт-Петербурга. Каждая камера характеризуется географическими координатами (широтой и долготой), которые служат основой для группировки.

Для решения поставленной задачи были выбраны пять методов кластеризации:

Самоорганизующаяся сеть (Self-Organizing Maps, SOM) – это тип искусственных нейронных сетей, обучаемых без учителя, которые выполняют проекцию многомерных входных данных на двумерную карту с сохранением топологической структуры исходного пространства [12]. Принцип работы заключается в итеративной адаптации весов нейронов: для каждого входного вектора определяется нейрон-победитель с минимальным евклидовым расстоянием, после чего его веса и веса топологических соседей смещаются в сторону входного вектора, что позволяет сформировать кластеры без предварительного задания их числа. В аналитической платформе Loginom данный метод реализован узлом «Самоорганизующаяся нейронная сеть».

В отличие от нейросетевого подхода, DBSCAN (Density-Based Spatial Clustering of Applications with Noise) относится к плотностным алгоритмам и группирует объекты, расположенные в областях с высокой плотностью, относит объекты в разреженных областях к шуму, что позволяет выявлять кластеры произвольной формы без предварительного задания их числа [13]. Принцип работы основан на двух параметрах: радиусе окрестности  $\epsilon$  и минимальном количестве точек  $\min\_samples$ . Для каждой точки подсчитывается количество соседей в радиусе  $\epsilon$ , после чего точки с достаточным числом соседей становятся ядрами кластеров, к которым присоединяются соседние точки, образуя кластеры произвольной формы. В Loginom алгоритм DBSCAN не входит в стандартный набор узлов, однако может быть реализован путём подключения сценария на языке Python с использованием библиотеки scikit-learn.



Классическим представителем центроидных методов является алгоритм k-means. Он разбивает множество объектов на заданное число  $k$  кластеров, минимизируя внутрикластерную сумму квадратов расстояний от каждой точки до центроида своего кластера [13]. Принцип работы заключается в итеративном пересчёте центроидов: на первом шаге случайным образом выбираются  $k$  начальных центров, затем каждая точка относится к ближайшему центроиду, после чего центроиды пересчитываются как средние значения точек в кластере, и процесс повторяется до сходимости. В Loginom метод k-means реализован в узле «Кластеризация».

Развитием k-means является алгоритм g-means, который автоматически определяет оптимальное число кластеров, предполагая, что данные в каждом кластере подчиняются нормальному (гауссовскому) распределению [13]. Принцип работы заключается в иерархическом разделении: алгоритм начинает с одного кластера, затем для каждого кластера проверяет гипотезу о том, что его данные распределены нормально. Если гипотеза отвергается, кластер разбивается на два с помощью k-means, и процесс повторяется до тех пор, пока все кластеры не будут признаны гауссовскими. В Loginom метод g-means реализуется в том же узле «Кластеризация».

Наконец, ЕМ-кластеризация представляет собой вероятностный метод, основанный на ЕМ-алгоритме (Expectation-Maximization), который предполагает, что данные могут быть описаны смесью многомерных нормальных распределений [14]. Принцип работы состоит из двух итеративных шагов: на Е-шаге вычисляются вероятности принадлежности каждого объекта к кластерам на основе текущих параметров распределений, на М-шаге пересчитываются параметры (математические ожидания, ковариации и веса) для максимизации функции правдоподобия. Алгоритм сходится, когда изменение параметров становится незначительным, при этом каждый объект может принадлежать нескольким кластерам с разной вероятностью, а итоговое отнесение производится по максимальному значению. В Loginom ЕМ-кластеризация реализована узлом «ЕМ Кластеризация».

Таблица 1 – Метрики сравнения кластеризаций [13]

| Метрика                                                                  | Смысл                                                                                                                       |
|--------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------|
| Rand Index (RI) – индекс Рэнда:<br>[0, 1]                                | Доля пар объектов, классифицированных одинаково в обеих кластеризациях                                                      |
| Fowlkes–Mallows Index (FMI) – индекс Фолкса–Маллоуса:<br>[0, 1]          | Среднее геометрическое точности и полноты для пар объектов, отнесённых в один кластер                                       |
| Jaccard Index (JI) – индекс Жаккара:<br>[0, 1]                           | Отношение пересечения пар объектов, отнесённых в один кластер, к их объединению                                             |
| Davies–Bouldin Index (DBI) – индекс Дэвиса – Болдуина<br>[0, $+\infty$ ] | Средняя «похожесть» каждого кластера с его наиболее близким соседом.<br>Чем меньше значение, тем лучше разделение кластеров |
| Partitioned Difference (PD) – разностное разделение                      | Количество пар объектов, которые в двух кластеризациях отнесены к разным кластерам                                          |
| Индекс силуэта<br>[-1, 1]                                                | Показывает, насколько объект похож на свой кластер по сравнению с другими.                                                  |

### Вид сценария кластеризации геоданных

Для настоящего исследования из открытых источников с официального сайта «Петростат» взят датасет, включающий в себя 20709 строк и состоящий из столбцов: «Порядковый номер», «Район», «Адрес», «Количество видеокамер». Для дальнейшей работы он дополнен вспомогательными столбцами такими, как: «Широта», «Долгота». Для корректности расчета метрик качества было выполнено преобразование геокоординат из градусов в метры [8].



|    | A                | B                | C                                                          | D        | E        | F                     | G           | H           |
|----|------------------|------------------|------------------------------------------------------------|----------|----------|-----------------------|-------------|-------------|
| 1  | Порядковый номер | Район            | Адрес                                                      | Широта   | Долгота  | Количество видеокамер | X (Крюгер)  | Y (Крюгер)  |
| 2  | 16,41            | Пушкинский район | город Павловск, Динамо, Пионерская улица, дом 15           | 59,65499 | 30,40516 | 3                     | 353725,0861 | 6618609,787 |
| 3  | 16,42            | Пушкинский район | город Павловск, Динамо, Пионерская улица, дом 17           | 59,65662 | 30,40547 | 2                     | 353749,3804 | 6618790,842 |
| 4  | 16,24            | Пушкинский район | город Павловск, Горная улица, дом 14                       | 59,66431 | 30,41132 | 2                     | 354112,8565 | 6619634,808 |
| 5  | 16,23            | Пушкинский район | город Павловск, Горная улица, дом 10                       | 59,66482 | 30,41225 | 4                     | 354167,1618 | 6619689,008 |
| 6  | 8,364            | Красносельский   | город Красное Село, Хвойный, дом 110                       | 59,66904 | 30,06942 | 18                    | 334875,8489 | 6620962,368 |
| 7  | 8,264            | Красносельский   | город Красное Село, территория Хвойный, дом 115            | 59,66953 | 30,07265 | 1                     | 335059,8977 | 6621009,013 |
| 8  | 8,365            | Красносельский   | город Красное Село, Хвойный, дом 115                       | 59,66953 | 30,07265 | 20                    | 335059,8977 | 6621009,013 |
| 9  | 16,9             | Пушкинский район | город Павловск, Артиллерийская улица, дом 2, опора освещен | 59,67795 | 30,45029 | 3                     | 356366,6391 | 6621068,327 |
| 10 | 16,89            | Пушкинский район | город Павловск, улица Мичурина, дом 28                     | 59,67839 | 30,42783 | 5                     | 355103,8044 | 6621165,706 |

Рис. 1. Исходные данные для кластеризации

Для обоснованного выбора параметров кластеризации на этапе предварительного анализа применяется график k-расстояний (метод локтя). Данный подход позволяет выявить естественную структуру данных, определить порог плотности или ориентировочное количество кластеров, что снижает субъективность при настройке алгоритмов и повышает воспроизводимость результатов [9].




Рис. 2. График «Метод локтя»

На рис. 2 видно, что график перестаёт существенно уменьшаться в точке 12, поэтому оптимальным количеством кластеров можно считать  $k = 12$ .




Рис. 3. Сценарий кластеризации в LogiDom

В подмодуле импорт реализованы два узла: «Excel файл», обеспечивающий импорт данных из Excel, и «Калькулятор», присваивающий каждой строке идентификатор, начиная с 0.




Рис. 4. Сценарий подмодели «Импорт»

Каждая подмодель выбранных кластеризаций, в первую очередь, состоит из узла выбранного метода кластеризации. Более подробно состав сценария рассмотрим на примере подмодели DBSCAN.




Рис. 5. Сценарий подмодели DBSCAN

На первом этапе выполнена предварительная очистка данных: удалены точки, классифицированные как шум ( $\text{Cluster} = -1$ ), и проведена фильтрация, а также группировка по ним (по каким адресам больше всего выбросов). Полученным кластерам присвоены идентификаторы с помощью функции `RowNum()`, рассчитаны: расстояния от центров кластеров, межкластерные расстояния, средние внутрикластерные расстояния. Полученные значения из таблиц преобразованы в переменные и собраны все вместе для удобства. Последним шагом вычисляется индекс Дэвиса-Болдуна (DBI) как отношение ранее вычисленных внутрикластерного расстояния и межкластерного расстояния.

Оценка качества выделенных кластеров проведена с использованием узла «Meta-silhouettes» из библиотеки «Loginom\_sklearn\_meta».




Рис. 6. Визуализация полученных кластеров k-means

Кроме того, для DBSCAN заранее были экспериментально подобраны значения  $\epsilon = 0,045$  (минимальный радиус окрестности вокруг точки данных) и  $\min\_samples = 4$  (расстояние до соседа). Первый параметр задавался в соответствии с размерностью пространства признаков: поскольку кластеризация выполнялась по двум координатам (широта и долгота), значение параметра принималось равным удвоенному числу признаков, т.е.  $\min\_samples = 4$ . Второй параметр был получен из графика k-ближайших расстояний, построенный с помощью узла «Python»:




Рис. 7. График k-ближайших расстояний

На рис. 7 видна точка перегиба, находящаяся в интервале 0,04-0,05. Именно она и



показывает расстояние до соседа, соответственно, взято среднее значение в этом диапазоне –  $\text{eps} = 0,045$ . В таблицах 2 и 3 приведены результаты расчета метрик качества кластеризации.

### Анализ полученных метрик кластеризации

Таблица 2 – Внутренние метрики оценки качества кластеризации для различных методов

| Внутренние метрики                  | Методы кластеризации |          |          |                     |                  |
|-------------------------------------|----------------------|----------|----------|---------------------|------------------|
|                                     | DBSCAN               | k-means  | g-means  | SOM (Сеть Кохонена) | ЕМ-кластеризация |
| Число кластеров, выделенных методом | 66                   | 18       | 19       | 8                   | 16               |
| Внутрикластерное расстояние         | 4669,45              | 615,62   | 588,10   | 1166,55             | 7805,51          |
| Межкластерное расстояние            | 19199,45             | 14341,85 | 13540,07 | 16990,89            | 7468,32          |
| Индекс Дэвиса-Болдуна (DBI)         | 0,24                 | 0,04     | 0,04     | 0,07                | 1,05             |
| Индекс силуэта                      | 0,12                 | 0,41     | 0,23     | 0,32                | 0,27             |

По совокупности внутренних метрик наилучшие результаты показывают центроидные методы k-means и g-means: они имеют минимальный DBI (0,04), высокие значения межкластерного расстояния и силуэта (0,41 и 0,23 соответственно), что свидетельствует о компактных и хорошо разделённых кластерах. SOM занимает промежуточное положение (DBI = 0,07, силуэт = 0,32). DBSCAN, несмотря на выделение 66 кластеров, демонстрирует умеренный DBI (0,24) и самый низкий силуэт (0,12), что объясняется его ориентацией на локальные сгущения и наличие шума, но при этом он остаётся полезным для детального анализа плотности. Наихудшие показатели у ЕМ-кластеризации (DBI = 1,05, силуэт = 0,27), что указывает на размытые границы кластеров. На рис. 8 приведена визуализация расположения кластеров на карте Санкт-Петербурга:




Рис. 8. Количество кластеров, выделенных DBSCAN (66) и k-means (18)

Из рис. 8. следует, что k-means разбил территорию Санкт-Петербурга на 18 примерно равных по размеру зон, что удобно для интерпретации и дальнейшего анализа. DBSCAN, напротив, выделил множество мелких кластеров, объединив несколько районов в один



крупный.

Исходя из сочетания наилучших значений DBI, числа кластеров и визуальной оценки, в качестве эталонного метода для попарного сравнения выбран k-means.

Таблица 3 – Внешние метрики попарного сравнения методов кластеризации

| Попарное сравнение метрик | Методы кластеризации |                        |         |                        |                           |
|---------------------------|----------------------|------------------------|---------|------------------------|---------------------------|
|                           | DBSCAN               | k-means<br>(эталонный) | g-means | SOM (Сеть<br>Кохонена) | ЕМ-<br>кластериза-<br>ция |
| Индекс Рэнда              | 0                    | -                      | 0       | 0                      | 0                         |
| Индекс Фолкса-Маллоуса    | 0,01                 | -                      | 0,01    | 0,01                   | 0                         |
| Индекс Жаккара            | 0                    | -                      | 0       | 0                      | 0                         |
| Разностное деление        | 4884                 | -                      | 114283  | 107370                 | 101,709                   |

Результаты попарного сравнения (табл. 3) показывают, что индексы Рэнда, Фолкса–Маллоуса и Жаккара для DBSCAN, g-means и SOM близки к нулю. Это ожидаемо, так как разные методы используют принципиально различные подходы к группировке. Наименьшее разностное деление ( $PD = 4884$ ) зафиксировано у DBSCAN, что указывает на относительную близость его разбиения к эталону, несмотря на значительно большее число кластеров. Наибольшие различия наблюдаются у g-means и SOM, что подчёркивает их принципиально иную структуру кластеризации.

Таким образом, k-means может быть рекомендован для обобщённого анализа пространственного распределения видеокамер, а DBSCAN – для детального выявления локальных зон высокой плотности.

### Определение центров кластеров и их практическое значение

После выполнения кластеризации для каждого кластера могут быть вычислены его центр – точка, вокруг которой группируются видеокамеры. На рис. 9 и рис. 10 показано расположение центров кластеров, полученных методом k-means, для Приморского и Центрального районов Санкт-Петербурга.




Рис. 9. Центры кластеров Приморского района




Рис. 10. Центры кластеров Центрального района

Такие центры кластеров могут служить опорными точками для организации единых центров мониторинга, которые объединяют тысячи видеокамер в единую сеть. В задачи такого центра входит непрерывный мониторинг общественных пространств, оперативное реагирование на преступления и правонарушения, использование распознавания лиц и номеров автомобилей для поиска правонарушителей.

Таким образом, кластерный анализ позволяет не только описать пространственную структуру размещения камер, но и предложить конкретные локации для размещения управляющих центров, что повышает эффективность всей системы видеонаблюдения.

### **Пространственный анализ размещения камер на основе центроидов кластеров**

Для сравнительной оценки пространственной структуры размещения видеокамер были выбраны два контрастных района Санкт-Петербурга: Центральный (туристический центр с высокой концентрацией камер) и Приморский (спальный район, где плотность видеонаблюдения значительно ниже). На основе кластеризации k-means, как эталонного метода, для каждого кластера, попадающего в эти районы, были вычислены его центроид – геометрический центр (среднее арифметическое координат всех видеокамер, входящих в кластер). Расположение центроидов для Приморского и Центрального районов показано на рис. 9 и 10 соответственно.

Визуальный анализ карт (рис. 9 и 10) показывает, что в Центральном районе центроиды кластеров расположены значительно плотнее, чем в Приморском. Это отражает высокую концентрацию видеокамер на ограниченной территории – в зоне основных туристических магистралей (Невский проспект, Большая Морская, Малая Садовая и др.). По данным кластеризации, на участке Невского проспекта плотность превышает 450 ед./км<sup>2</sup> (в 4,5 раза выше средней по району), а на Большой Морской и Малой Садовой достигает 300 ед./км<sup>2</sup>. В Приморском районе даже в локальных точках концентрации плотность не превышает 80–90 ед./км<sup>2</sup>, следовательно, центроиды распределены более равномерно, что соответствует спальной застройке с меньшей плотностью камер.



Количественное сравнение пространственных характеристик кластеров (табл. 4) подтверждает визуальные наблюдения. Для каждого кластера были рассчитаны: среднее внутрикластерное расстояние (компактность группировки камер относительно центроида) и среднее расстояние между соседними центроидами (характеризует частоту размещения «узлов» видеонаблюдения).

Таблица 4 – Кластерные показатели Центрального и Приморского районов

| Показатель                                    | Центральный район | Приморский район |
|-----------------------------------------------|-------------------|------------------|
| Кол-во кластеров, входящих в район, ед.       | 10                | 10               |
| Среднее внутрикластерное расстояние, м        | 2769,40           | 4017,28          |
| Среднее расстояние между центроидами, км      | 1,79              | 7,13             |
| Плотность камер в районе, ед./км <sup>2</sup> | 101,99            | 32,23            |

Как видно из таблицы 4, в Центральном районе внутрикластерные расстояния существенно меньше (2,8 км против 4,0 км), что означает более компактную группировку камер вокруг своих центроидов. Среднее расстояние между центроидами в центре в 4 раза меньше (1,79 км против 7,13 км), а плотность камер – в 3 раза выше (101,99 против 32,23 ед./км<sup>2</sup>). Эти количественные различия наглядно демонстрируют, что в туристической зоне видеокamеры сконцентрированы значительно плотнее и образуют более частую пространственную сетку центров кластеров, чем в спальном Приморском районе.

Полученные центроиды кластеров могут служить опорными точками для организации единых центров мониторинга. В Центральном районе, где центроиды расположены часто, потребуется больше таких центров (или один, но с высокой пропускной способностью), а в Приморском – меньше, но с большим радиусом покрытия. Таким образом, предложенный подход на основе центроидов может быть использован при планировании развития систем видеонаблюдения в городской агломерации.

На рис. 11 представлена столбчатая диаграмма, наглядно показывающая плотность видеокamер в двух районах:




Рис. 11. Сравнение плотности видеокamер в Центральном и Приморском районах

На рис. 12 представлена иллюстрация связи плотности расположения видеокamер с раскрываемостью преступлений в Центральном и Приморском районах. Для Центрального



района, характеризующегося высокой плотностью камер (324 ед./км<sup>2</sup>), показатель раскрываемости составляет 61,7 %, тогда как в Приморском районе при плотности 52,4 ед./км<sup>2</sup> раскрываемость равна 49,8 %. Таким образом, наблюдается тенденция: районы с более высокой плотностью видеонаблюдения демонстрируют и более высокий уровень раскрываемости.




Рис. 12. Иллюстрация связи плотности расположения видеокамер с раскрываемостью в Центральном и Приморском районах

### Закключение

В результате проведенного исследования выполнен сравнительный анализ пяти методов кластеризации: DBSCAN, k-means, g-means, SOM, EM-кластеризация для пространственного распределения видеокамер Санкт-Петербурга. На основе внутренних метрик установлено, что наилучшую компактность и разделимость кластеров обеспечивают центроидные методы k-means и g-means. Метод k-means, выделивший 18 кластеров, признан эталонным для пространственного анализа.

Пространственный анализ центроидов кластеров, полученных методом k-means, показывает, что в туристическом Центральном районе видеокамеры сконцентрированы значительно плотнее, чем в спальном Приморском районе. Это подтверждается существенно меньшим внутрикластерным расстоянием (камеры группируются вокруг центроидов гораздо компактнее), более высокой плотностью камер (в несколько раз больше на единицу площади) и более частым расположением самих центроидов (среднее расстояние между ними заметно меньше).

Таким образом, полученные центроиды кластеров могут служить обоснованными опорными точками для размещения единых центров мониторинга, что позволяет повысить оперативность реагирования и эффективность управления видеопотоками. Предложенный подход может быть использован при планировании развития систем видеонаблюдения в городских агломерациях.



## СПИСОК ЛИТЕРАТУРЫ

1. *Welsh B. C.* Effects of closed circuit television surveillance on crime / B. C. Welsh, D. P. Farrington // *Campbell systematic reviews*. – 2008. – Vol. 4, No 1. – P. 1–73.
2. *Welsh B.* Closed-circuit television surveillance and crime prevention: a systematic review / B. Welsh, D.P. Farrington. – Stockholm: National Council for Crime Prevention, 2007. – 112 p.
3. *Cerezo A.* CCTV and crime displacement: a quasi-experimental evaluation / A. Cerezo // *European Journal of Criminology*. – 2013. – Vol. 10, No 2. – P. 179–191. DOI: 10.1177/1477370812468379.
4. *Piza E. L.* The crime prevention effect of CCTV in public places: a propensity score analysis / E. L. Piza // *Journal of Crime and Justice*. – 2018. – Vol. 41, No 1. – P. 14–30. DOI: 10.1080/0735648X.2016.1226931.
5. *Park H. H.* Measuring the crime displacement and diffusion of benefit effects of open-street CCTV in South Korea / H.H. Park, G.S. Oh, S.Y. Paek // *International Journal of Law, Crime and Justice*. – 2012. – Vol. 40, No 3. – P. 179–191.
6. *Lai Y. L.* Does the police-monitored CCTV scheme really matter on crime reduction? A quasi-experimental test in Taiwan's Taipei City / Y. L. Lai, C. J. Sheu, Y. F. Lu // *International Journal of Offender Therapy and Comparative Criminology*. – 2019. – Vol. 63, No 1. – P. 113–134. DOI: 10.1177/0306624X18780101.
7. *Санина А. Г.* Информационные технологии в обеспечении безопасности: анализ эффективности систем видеонаблюдения / А. Г. Санина, Ю. А. Сафронова, А. Г. Атаева // *Информационное общество*. – 2025. – № 4. – С. 138–146.
8. *Андронов С. А.* Сравнение методов кластеризации геоданных для сетевой компании в пределах городской агломерации / С. А. Андронов // *Аэрокосмическое приборостроение и эксплуатационные технологии: сб. докладов Седьмой международной научной конференции*. – Санкт-Петербург, 2026. – С. 3–11. DOI: 10.31799/978-5-8088-2132-3-2026-7-2-3-11.
9. Scikit-learn. Clustering [Электронный ресурс]. – URL: <https://scikit-learn.org/stable/modules/clustering.html> (дата обращения: 23.03.2026).
10. KNIME Analytics Platform [Электронный ресурс]. – URL: <https://www.knime.com/knime-analytics-platform> (дата обращения: 23.03.2026).
11. Loginom: Low-code платформа для реализации аналитических процессов [Электронный ресурс]. – URL: <https://loginom.ru/> (дата обращения: 23.03.2026).
12. *Панферова Е. В.* Сравнительная оценка методов кластеризации в работе с большими данными / Е. В. Панферова, Р. А. Матюшин // *Вестник Пермского университета. Математика. Механика. Информатика*. – 2024. – № 2 (65). – С. 61–67. DOI: 10.17072/1993-0550-2024-2-61-67.
13. *Андронов С. А.* Интеллектуальный анализ данных без программирования: лабораторный практикум / С. А. Андронов. – СПб.: ГУАП, 2024. – 200 с.
14. Loginom. Кластеризация [Электронный ресурс]. – URL: <https://help.loginom.ru/userguide/processors/datamining/clustering.html> (дата обращения: 20.03.2026).

## ИНФОРМАЦИЯ ОБ АВТОРАХ

**Журавлева Юлия Андреевна**

Студент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

Россия, 190000, Санкт-Петербург, ул. Большая Морская, д.67, лит. А

E-mail: [yliazhuravlik@gmail.com](mailto:yliazhuravlik@gmail.com)



**Андронов Сергей Александрович**

Канд. техн. наук, доцент

Санкт-Петербургский государственный университет аэрокосмического приборостроения

Россия, 190000, Санкт-Петербург, ул. Большая Морская, д.67, лит. А

E-mail: andronov\_00@mail.ru

**INFORMATION ABOUT THE AUTHORS**

**Zhuravleva Julia Andreevna**

Student

Saint-Petersburg State University of Aerospace Instrumentation

67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: yliazhuravlik@gmail.com

**Andronov Sergey Alexandrovich**

PhD. tech. Sciences, associate Professor

Saint-Petersburg State University of Aerospace Instrumentation

67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: andronov\_00@mail.ru

*Дата поступления: 10.04.2026*

*Дата принятия: 12.04.2026*