

РАСПОЗНАВАНИЕ ОБРАЗОВ И ОБРАБОТКА ИЗОБРАЖЕНИЙ

УДК 004.932.2

ДЕТЕКТИРОВАНИЕ ТЕРМАЛЬНЫХ АНОМАЛИЙ НА НОЧНЫХ СНИМКАХ ВУЛКАНОВ¹

© 2020 г. А. Н. Камаев^а, С. П. Королёв^а, А. А. Сорокин^а, И. П. Урманов^{а,*}

^аВЦ ДВО РАН, Хабаровск, Россия

*e-mail: urmanov@ccfebras.ru

Поступила в редакцию 07.11.2018 г.

После доработки 07.06.2019 г.

Принята к публикации 30.09.2019 г.

Обсуждается проблема выявления возникновения и развития термальных аномалий на изображениях вулканов, полученных в ночное время суток в видимом и ближнем инфракрасном диапазонах. Предложен алгоритм обнаружения и классификации подобных аномалий, а также проведена его апробация на данных архива видеонаблюдения за вулканами Камчатки. Полученные результаты позволяют говорить о возможности применения созданного решения в задачах оперативного мониторинга вулканической активности на Дальнем Востоке России.

DOI: 10.31857/S0002338819060088

Введение. В рамках исследований по развитию программных средств системы видеонаблюдения за вулканами Камчатки [1] авторами были разработаны специализированные алгоритмы [2, 3], обеспечивающие фильтрацию и автоматизированный поиск фотоснимков с признаками активности указанных природных объектов в дневное время суток. Для обработки данных с камер, которые ведут ночную съемку, требуются отдельные решения, которые позволят выявлять возникновение и развитие термальных аномалий. В первую очередь речь идет о снимках с областью аномалии, яркость которой превышает яркость окрестности и спадает от центра к краям изображения (рис. 1).

В [4] представлен метод обнаружения аномалии в заранее выделенной области изображения, однако он не позволяет локализовать аномалию на снимке и обладает рядом ограничений, связанных с периодической посторонней засветкой и переменной видимостью вулкана. Кроме того, его применение осложняется наличием на изображениях спекл-шума [5]. Наиболее очевидный способ обнаружения термальных аномалий – это поиск участков изображения, яркость которых выше определенного порога, как это показано в [6, 7]. Данный метод хорошо подходит для термальных камер [8, 9], но неприменим для используемых камер, снимающих в широком диапазоне, который включает видимый и ближний инфракрасный спектры. Яркие области на таких снимках соответствуют не только высокотемпературным, но и освещенным областям. Солнечная или лунная засветка вдоль контура вулкана, как правило, ярче, чем температурные аномалии среднего и небольшого размера, что делает невозможным их обнаружение исключительно по яркостному признаку.

В статье рассматривается ряд признаков, позволяющих наиболее точно определить, является ли некоторая выделенная область температурной аномалией. Для выделения областей потенциальных температурных аномалий используется DoG (difference of gaussian) [10] детектор. Он позволяет не просто находить яркостные максимумы на изображениях, но и справляется с фильтрацией шума, а также дает необходимую для построения признаков информацию о масштабе области потенциальной аномалии. Дается описание процедуры построения признаков потенциальных аномалий и решение задачи классификации аномалий на истинные и ложные на основе вектора этих признаков. Применительно к настоящей задаче исследуются следующие классификаторы: наивный байесовский [11], SVM (support vector machine) [12] и K-means [13]. Представ-

¹ Исследование проведено при частичной финансовой поддержке Комплексной программы фундаментальных научных исследований ДВО РАН “Дальний Восток” (проект № 18-5-091). Численные расчеты проводились с применением методов и технологии, разработанных при финансовой поддержке РФФИ (проект № 18-29-03196).

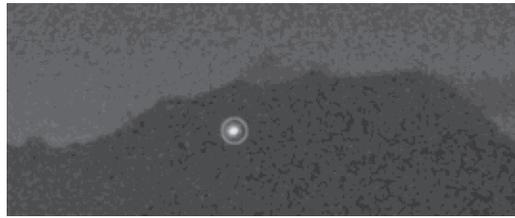


Рис. 1. Фрагмент снимка вулкана, содержащий термальную аномалию

лены результаты обнаружения термальных аномалий на ночных снимках, полученных с помощью видеокамеры Axis P1343, которая осуществляет непрерывное наблюдение за вулканом Шивелуч.

1. Обнаружение термальных аномалий. 1.1. Поиск центров аномалий. Обозначим через $L(x, y, \sigma) = G(x, y, \sigma) * I(x, y)$ изображение, полученное в результате свертки яркостной составляющей исходного изображения $I(x, y)$ с функцией Гаусса $G(x, y, \sigma) = 0.5\pi^{-1}\sigma^{-2}e^{-(x^2+y^2)/(2\sigma^2)}$ по координатам x и y . Построим $N + 2$ слоя $L_j(x, y) = L(x, y, \sigma_0\sigma_\Delta^j)$, где параметр σ_0 задает начальный масштаб, на котором могут быть найдены аномалии, параметр σ_Δ определяет шаг масштаба между слоями масштабного представления изображения, $j = \overline{0, N + 1}$. Параметр σ_0 выбирается достаточно большим, чтобы снизить влияние высокочастотного шума на $I(x, y)$, но при этом не потерять аномалии минимально допустимого размера. Для термальных аномалий, наблюдаемых в данной работе, были выбраны значения параметров $\sigma_0 = 0.4$, $\sigma_\Delta = 1.3$ и количество слоев $N = 14$.

Для обнаружения центров термальных аномалий вычисляются DoG-уровни $D_k(x, y) = L_k(x, y) - L_{k+1}(x, y)$, $k = \overline{0, N}$. В качестве центров потенциальных аномалий рассматриваются точки с координатами $\mathbf{c} = (c_x, c_y, c_i)$, такие, что $D_{c_i}(c_x, c_y) > D_{c_i}(x_c, y_c)$, где $c_i = (c_i - 1, c_i, c_i + 1)$, $x_c = (c_x - 1, c_x, c_x + 1)$, $y_c = (c_y - 1, c_y, c_y + 1)$, и выполняется условие $c_i \neq c_j \vee x_c \neq x_j \vee y_c \neq y_j$.

1.2. Область, занимаемая аномалией. Для описания процедуры выделения областей, занимаемых аномалиями на слое $D_i(x, y)$, $i \in \overline{1, N - 1}$, введем $M(\mathbf{p}) = \{(p'_x, p'_y) \mid |p_x - p'_x| \leq 1 \wedge |p_y - p'_y| \leq 1 \wedge \mathbf{p} \neq \mathbf{p}'\}$ – множество соседей точки $\mathbf{p} = (p_x, p_y)$ на слое $D_i(x, y)$. Результаты работы алгоритма будем записывать в изображение-маску $\mathbf{A} = \{\mathbf{A}_{x,y}\}$, где $x = \overline{0, w - 1}$, $y = \overline{0, h - 1}$, а w и h – ширина и высота исследуемого изображения. Пусть обнаружено K центров аномалий на слое i : $\mathbf{c}_k = (c_{kx}, c_{ky}, c_{ki})$, где $c_{ki} = i$, а $k = \overline{1, K}$, тогда алгоритм разметки областей, принадлежащих данным аномалиям, можно записать следующим образом.

Шаг 1. Зададим начальные значения $\mathbf{A}_{x,y} = 0$ для всех x, y .

Шаг 2. Для $k = \overline{1, K}$: присвоить $\mathbf{A}_{c_{kx}, c_{ky}} = k$, поместить точку (c_{kx}, c_{ky}) в очередь Q .

Шаг 3. Пока $Q \neq \emptyset$ выполнять шаги 3а, 3б.

Шаг 3а. Извлечь точку из очереди: $\mathbf{p} \leftarrow Q$.

Шаг 3б. Если выполняется условие $D_i(p_x, p_y) \geq 0.1D_i(c_{A_p x}, c_{A_p y})$ то $\forall \mathbf{p}' \in M(\mathbf{p}) \wedge \mathbf{A}_{\mathbf{p}'} = 0 \wedge D_i(p'_x, p'_y) < D_i(p_x, p_y)$: присвоить $\mathbf{A}_{\mathbf{p}'} = \mathbf{A}_{\mathbf{p}}$, поместить \mathbf{p}' в очередь $Q \leftarrow \mathbf{p}'$.

После выполнения алгоритма разметки областей для каждой точки i -го изображения маска \mathbf{A} будет содержать либо индекс аномалии, которой принадлежит точка, либо ноль, если точка не принадлежит какой-либо аномалии.

2. Признаки термальных аномалий. Лишь небольшое число найденных потенциальных термальных аномалий в действительности являются результатом вулканической активности. Можно выделить ряд признаков, позволяющих произвести классификацию выделенных областей на истинные и ложные аномалии. Далее рассмотрим эти признаки и способ их построения для i -го масштабного слоя.



Рис. 2. Нормализованный $D_k(x, y)$ слой изображения

2.1. **Признаки максимума аномалии.** К признакам, которые могут быть рассчитаны для максимума потенциальной термальной аномалии, можно отнести величину максимума, вытянутость и яркость. Рассмотрим эти признаки.

Величина k -го максимума – это значение $D_i(c_{kx}, c_{ky})$. Как правило, для термальных аномалий характерны значения выше определенного порога, тогда как максимумы, вызванные шумом на изображении, имеют меньшую величину.

Признак вытянутости показывает, насколько различается скорость убывания функции вокруг максимума в разных направлениях. Для термальных аномалий, сгенерированных вулканами, различия в скорости невелики, тогда как для ярких пятен, образующихся у контура вулкана в лучах восходящего солнца, скорость убывания функции в одном направлении существенно превышает скорость убывания в другом (рис. 2).

Для вычисления признака вытянутости интерполируем участок изображения $D_i(u, v)$, $u = c_{kx} - 1, c_{kx}, c_{kx} + 1$, $v = c_{ky} - 1, c_{ky}, c_{ky} + 1$ квадратичной функцией

$$f(x, y) = \sum_{i=0}^2 \sum_{j=0}^2 a_{3i+j} x^i y^j,$$

коэффициенты a_l , $l = \overline{0,8}$, для которой можно рассчитать, подставив точки (u, v) и значения $D_i(u, v)$ в уравнение. Воспользовавшись одним из методов минимизации, например методом Ньютона, найдем максимум функции $f(x, y)$ $\mathbf{c}' = (c'_x, c'_y)$. Обратим внимание, что $c_{kx} \neq c'_x$ и $c_{ky} \neq c'_y$, так как \mathbf{c}_k – приближенное дискретное положение максимума, а \mathbf{c}' – точное положение максимума функции, интерполирующей участок $D_i(u, v)$. Далее построим матрицу Гессе

$$\mathbf{H}(x, y) = \begin{pmatrix} \partial^2 f(x, y) / \partial x^2 & \partial^2 f(x, y) / \partial x \partial y \\ \partial^2 f(x, y) / \partial y \partial x & \partial^2 f(x, y) / \partial y^2 \end{pmatrix}.$$

Если λ_{\min} и λ_{\max} – наименьшее и наибольшее собственное число матрицы $\mathbf{H}(c'_x, c'_y)$ соответственно, то признак вытянутости определяется соотношением $\sqrt{\lambda_{\min} / \lambda_{\max}}$.

Последний признак максимума аномалии – его яркость. Она описывается значением $L_i(c_{kx}, c_{ky})$. Для реальных термальных аномалий это значение, как правило, превышает некоторый порог.

2.2. **Признаки области аномалии.** В качестве признаков области аномалии предлагается использовать коэффициенты периметра, асимметричности границ и пика. Рассмотрим эти коэффициенты.

Коэффициент периметра p'_k/p_k показывает соотношение периметров k -й аномалии на i -м слое p_k и минимально возможного периметра аномалии такой же площади p'_k , $k = \overline{1, K}$:

$$p'_k = 2 \sqrt{\pi \sum_{x,y} \delta_{A_{xy},k}},$$

где $\delta_{A_{xy},k}$ – символ Кронекера. Периметр

$$p_k = \sum_{x,y} \eta_k(x,y),$$

где $\eta_k(x,y) = (1 - \delta_{A_{xy},k})(\delta_{A_{x+1,y},k} + \delta_{A_{x-1,y},k} + \delta_{A_{x,y+1},k} + \delta_{A_{x,y-1},k})$.

Для корректной обработки аномалий, которые поместились в область изображения лишь частично, следует обнулить точки карты A , находящиеся на границах изображения.

Коэффициент асимметричности границ показывает, насколько равномерно спадает яркость аномалии к ее границе. Множество яркостей граничных точек k -й аномалии $\Gamma_k = \{L_i(x,y) | \eta_k(x,y) > 0\}$, в этом множестве выделим два подмножества $\Gamma_k^{\min} \subset \Gamma_k$ и $\Gamma_k^{\max} \subset \Gamma_k$, которые содержат 10% наименьших и 10% наибольших яркостей из Γ_k соответственно. С учетом этих множеств коэффициент асимметричности границ можно определить на основе отношения

$$t = \frac{L_i(c_{kx}, c_{ky}) - l^{\min}}{L_i(c_{kx}, c_{ky}) - l^{\max}},$$

где

$$l^{\min} = |\Gamma_k^{\min}|^{-1} \sum_{l \in \Gamma_k^{\min}} l,$$

$$l^{\max} = |\Gamma_k^{\max}|^{-1} \sum_{l \in \Gamma_k^{\max}} l.$$

Для аномалий, часть площади которых находится за границей экрана, знаменатель отношения t будет близок к нулю, что приведет к очень большим значениям, негативно влияющим на классификацию. Чтобы избавиться от этих выбросов, ограничим t интервалом $[-\pi/2; \pi/2]$, для этого коэффициент асимметричности границ будем находить по формуле

$$\arctan\left(\frac{t - \theta}{\Delta}\right),$$

где $\theta = 0.5(t_{\min} + t_{\max})$, $\Delta = t_{\max} - \theta$. При этом максимальное и минимальное значения t определялись на основе значений класса истинных аномалий обучающей выборки, описанной в следующем разделе. В данной работе были использованы значения $\theta = 20$, $\Delta = 20$.

Коэффициент пика показывает, насколько яркость центра аномалии больше средней яркости границ:

$$L_i(c_{kx}, c_{ky}) - |\Gamma_k|^{-1} \sum_{l \in \Gamma_k} l.$$

3. Классификация. Каждой потенциальной аномалии может быть поставлен в соответствие вектор из шести параметров: величина максимума, вытянутость, яркость, коэффициенты периметра, асимметричности и пика. Набор этих параметров позволяет отнести аномалию к истинной (термальной) или к ложной (освещенный участок изображения или шум). Разметим вручную набор аномалий, извлеченных из архива изображений вулканов Камчатки [14]. В общей сложности на этих изображениях было размечено $M_f = 1000$ ложных и $M_t = 1000$ истинных аномалий. Будем использовать эти данные для обучения трех классификаторов: наивный байесовский классификатор, SVM и K-means.

3.1. Наивный байесовский классификатор. Построим гистограммы распределения значений параметров аномалий из обучающей выборки. На рис. 3 показаны такие гистограммы для каждого из параметров, построенные для 30 интервалов. Как видно из гистограмм, ни один признак не позволяет однозначно разделить истинные и ложные аномалии. Согласно

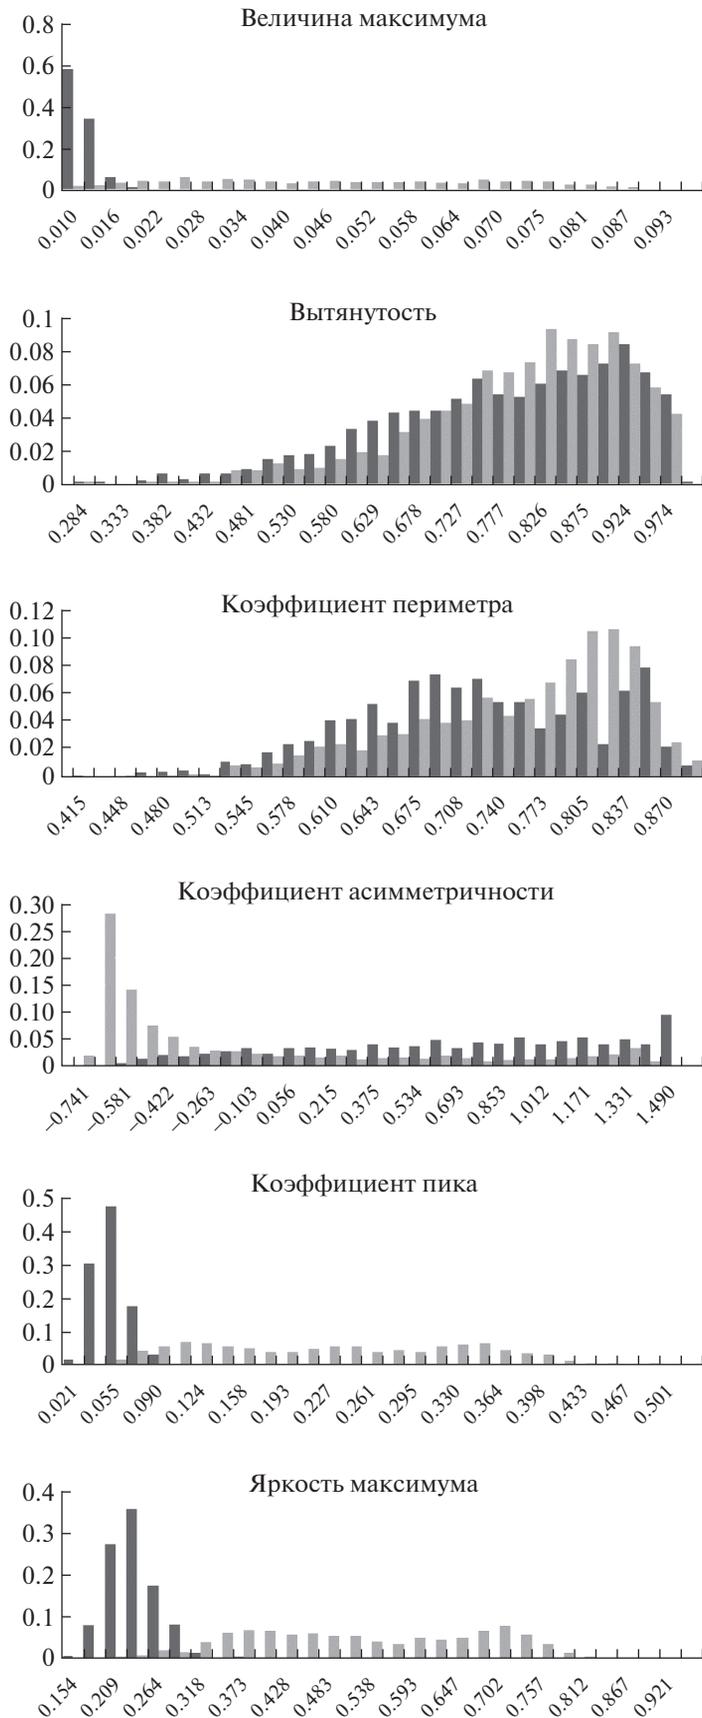


Рис. 3. Гистограммы распределения значений каждого признака аномалий для 30 интервалов: ■ – ложные аномалии; ▒ – истинные аномалии

теореме Байеса, вероятность того, что аномалия принадлежит классу C ($C = C_t$ – класс истинных аномалий, $C = C_f$ – класс ложных аномалий), задается формулой

$$p(C|\mathbf{F}) = \frac{p(C)p(\mathbf{F}|C)}{p(\mathbf{F})},$$

где $\mathbf{F} = (F_1, F_2, \dots, F_6)$ – вектор параметров.

Класс, к которому относится исследуемая аномалия, определяется максимальной вероятностью:

$$C(\mathbf{F}) = \arg \max_{C=C_t, C_f} p(C|\mathbf{F}).$$

Предположив независимость параметров, можно переписать эту вероятность следующим образом:

$$p(C|\mathbf{F}) = \frac{p(C)p(F_1|C) \cdot \dots \cdot p(F_6|C)}{p(\mathbf{F})}.$$

Знаменатель $p(\mathbf{F})$ можно отбросить, так как он не зависит от класса C , а для решения задачи классификации важно не реальное значение вероятности $p(C|\mathbf{F})$, а соотношение вероятностей $p(C_t|\mathbf{F})$ и $p(C_f|\mathbf{F})$. Вероятности $p(C_t)$ и $p(C_f)$ могут быть рассчитаны на основе встречаемости классов в обучающих данных. Но, учитывая то, что абсолютное значение $p(C|\mathbf{F})$ нас не интересует, более практичным решением будет оставить $p(C_t)$ в качестве параметра классификатора, определяющего его чувствительность к истинным аномалиям. Повышая это значение, можно регулировать границу между неверно классифицируемыми истинными и ложными аномалиями. В настоящей работе были выбраны значения $p(C_t) = 0.96$ при $p(C_f) = 0.04$ как наиболее оптимальные. Вероятности $p(F_i|C)$ можно определить на основе гистограмм параметров (рис. 3), предварительно применив к ним сглаживание, чтобы избежать нулевых значений в допустимом диапазоне параметров.

3.2. Н о р м а л и з а ц и я д а н н ы х. Наивный байесовский классификатор рассматривает параметры независимо друг от друга, тогда как SVM и K-means работают в едином пространстве параметров. В связи с этим для использования этих методов необходимо произвести нормализацию векторов параметров, чтобы исключить доминирование одних параметров над другими. Пусть имеется два вектора, описывающие истинные и ложные аномалии из обучающих данных: $\mathbf{F}_i^t = (F_{i1}^t, F_{i2}^t, \dots, F_{iN}^t)$ и $\mathbf{F}_j^f = (F_{j1}^f, F_{j2}^f, \dots, F_{jN}^f)$, где $i = \overline{1, M_t}$, $j = \overline{1, M_f}$, а $N = 6$ или $N = 7$ (см. разд. 3.3). Тогда вектор математических ожиданий параметров и их дисперсий

$$\bar{\mathbf{F}}^c = M_c^{-1} \sum_{i=1}^{M_c} \mathbf{F}_i^c,$$

$$\mathbf{D}^c = M_c^{-1} \sum_{i=1}^{M_c} (\mathbf{F}_i^c - \bar{\mathbf{F}}^c) \text{diag}(\mathbf{F}_i^c - \bar{\mathbf{F}}^c),$$

где $c = t, f$. Используя $\bar{\mathbf{F}}^c$ и \mathbf{D}^c , запишем вектор левых $\mathbf{L} = (L_1, L_2, \dots, L_N)$ и правых $\mathbf{R} = (R_1, R_2, \dots, R_N)$ границ параметров, где

$$L_k = \min_{c=t, f} (\bar{F}_k^c - 3\sqrt{D_k^c}),$$

$$R_k = \max_{c=t, f} (\bar{F}_k^c + 3\sqrt{D_k^c}), \quad k = \overline{1, N}.$$

Векторы \mathbf{L} и \mathbf{R} определяют вектор масштаба $\mathbf{S} = (S_1, S_2, \dots, S_N)$, $S_k = (R_k - L_k)^{-1}$. С помощью векторов \mathbf{L} и \mathbf{S} нормализуем исходный вектор параметров \mathbf{F} :

$$\tilde{\mathbf{F}} = (\mathbf{F} - \mathbf{L}) \text{diag}(\mathbf{S}).$$

3.3. Машина опорных векторов (SVM). SVM находит разделяющую гиперплоскость в пространстве нормализованных параметров $\tilde{F}_1, \tilde{F}_2, \dots, \tilde{F}_6$ либо в пространстве большей размерности, куда могут быть спроецированы векторы параметров аномалий. Поскольку заранее неизвестно, являются ли классы истинных и ложных аномалий линейно разделимыми, будем использовать SVM и радиальную базисную функцию (kernel trick) [15]:

$$k(\mathbf{x}, \mathbf{x}') = e^{-\gamma \|\mathbf{x} - \mathbf{x}'\|^2},$$

где \mathbf{x} и \mathbf{x}' – векторы параметров двух аномалий, а γ – параметр алгоритма. Уменьшение параметра γ приближает SVM к линейному, а увеличение позволяет точнее построить разделяющую плоскость для обучающих данных, но может приводить к ухудшению обобщающей способности построенного классификатора. Для поиска разделяющей плоскости SVM строит две плоскости, параллельные искомой и расположенные по разные стороны от нее на одинаковом расстоянии. Расстояние между этими двумя плоскостями называется зазором, который максимизируется. Точки, представляющие истинные аномалии, должны быть выше одной плоскости, а точки, представляющие ложные аномалии, – выше другой плоскости. Увеличение зазора между плоскостями ведет к тому, что какая-то часть аномалий оказывается ниже соответствующей им плоскости на некотором расстоянии от нее. Сумма таких расстояний в ходе построения разделяющей плоскости минимизируется. Коэффициент этой суммы C определяет баланс между величиной зазора и количеством аномалий из обучаемого набора, лежащих внутри зазора.

Для поиска оптимальных значений параметров γ и C производился поиск по сетке с узлами $\gamma_i = 2^{i-1}$ и $C_j = 10^j$, $i, j = \overline{0, 7}$. Для каждого значения параметров сетки строилась разделяющая плоскость на основе половины обучающей выборки и оценивалось количество неверно классифицированных аномалий из второй половины выборки. В результате были выбраны значения параметров $\gamma = 4$, $C = 1000$.

Кроме стандартного набора из шести параметров, описывающих каждую аномалию, использовался также дополнительный седьмой параметр – номер масштабного слоя, на котором была найдена данная аномалия. Сам по себе номер слоя не позволяет различать истинные и ложные аномалии, в связи с этим он не был использован в наивном классификаторе Байеса. Но номер слоя может влиять на разделимость классов истинных и ложных аномалий через другие параметры. Чем ниже масштабный слой, тем больше шума присутствует на нем и тем больше сказывается дискретный характер изображения при определении параметров, связанных с областью аномалии. Для более высоких масштабных слоев характерны меньшие перепады яркости и полное отсутствие шума.

3.4. Классификатор K-means. Идея классификатора K-means заключается в том, чтобы расположить в пространстве параметров некоторое количество точек, каждая из которых определяет какой-либо класс. Класс анализируемой аномалии будет соответствовать классу той точки, которая лежит ближе всего в пространстве параметров. В данной работе для описания истинных и ложных аномалий использовалось по 512 точек, размещенных с помощью алгоритма K-means на основе обучающей выборки. Как и для SVM, для K-means рассматривались шестимерные, а также семимерные нормализованные векторы параметров с дополнительным параметром – номером масштабного слоя.

3.5. Результаты. Тестирование разработанных алгоритмов классификации проводилось на 114447 ложных и 1408 истинных аномалиях, обнаруженных на изображениях вулкана Шивелуч, полученных с использованием видеокамеры Axis P1343. В камере установлена RGB CMOS-матрица (1/4 дюйма, прогрессивная развертка) и применяется вариофокальный объектив 3–8 мм со светосилой F1.0. Имеется механический отсекающий ИК-фильтр, при использовании которого возможна работа видеокамеры в условиях естественной ночной освещенности, соответствующей в видимом диапазоне 0.05 лк. Диафрагма в объективе управляется автоматически (DC-Iris).

Обработка данных выполнялась с использованием ресурсов вычислительных систем гибридной и классической архитектуры ЦКП “Центр данных ДВО РАН” [16]. Таблица содержит информацию о том, сколько истинных и ложных аномалий удалось обнаружить каждым из используемых классификаторов. Строки таблицы соответствуют используемым классификаторам: НКБ – наивный классификатор Байеса, SVM6 и SVM7 – машина опорных векторов с шестью и семью мерными векторами параметров, K6, K7 – K-means с шестью и семью мерными векторами параметров. Столбцы таблицы содержат следующую информацию: FN (false negative) – про-

Таблица. Результаты классификации аномалий

Классификаторы	FN	FP	Err
	%		
НКБ	4.19	3.88	3.88
SVM6	2.63	2.75	2.75
SVM7	1.85	2.08	2.08
K6	3.76	3.58	3.58
K7	2.56	2.00	2.01

цент истинных аномалий, которые не были обнаружены, FP (false positive) – процент ложных аномалий, которые были распознаны как истинные, Err – общая ошибка классификатора в процентах.

Как видно из таблицы, использование седьмого признака позволило снизить ошибку классификации, наилучшие результаты показали классификаторы K-means и SVM. Несмотря на то, что общая ошибка для K-means с семью параметрами меньше, чем для SVM7, процент нераспознанных истинных аномалий для SVM7 оказался ниже, что является наиболее важным фактором в задаче мониторинга вулканической активности. Хуже остальных оказался наивный классификатор Байеса, что было ожидаемо, так как он не учитывает связи между параметрами.

Дополнительно, чтобы избежать влияния реальных термальных аномалий, вызванных техногенными и иными факторами (рис. 4), на этапе поиска центров аномалий использовалась бинарная маска, выделяющая активную область вулкана. Пример такой маски представлен на рис. 5.

Ошибки в обнаружении аномалии (рис. 6) обусловлены рядом объективных причин:

неоднородность атмосферы активной части вулкана приводит к сглаживанию яркости на снимках, в связи с чем часть аномалий имеет особую нестандартную форму;

яркость некоторых аномалий не превышает перепада яркости, вызываемого шумом на изображении;

аномалии, представляющие лавовые потоки, имеют уникальную форму, что затрудняет их распознавание.

Для решения перечисленных проблем необходимо увеличение количества рассматриваемых классов аномалий и расширение обучающей выборки.

**Рис. 4.** Пример ложных аномалий вне активной области вулкана

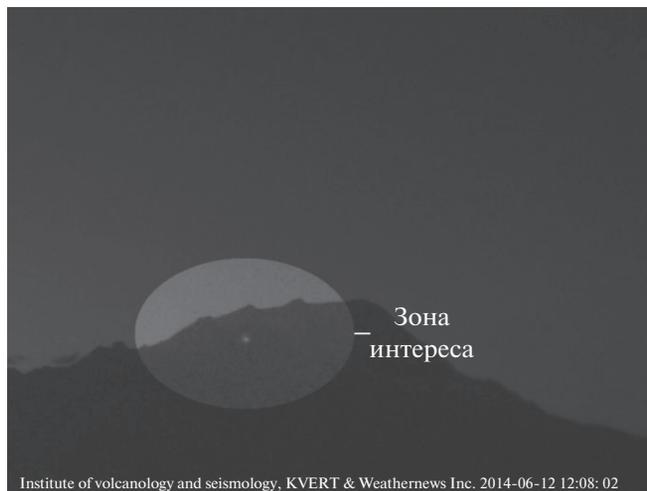


Рис. 5. Зона интереса на исходном изображении, выделяемая маской

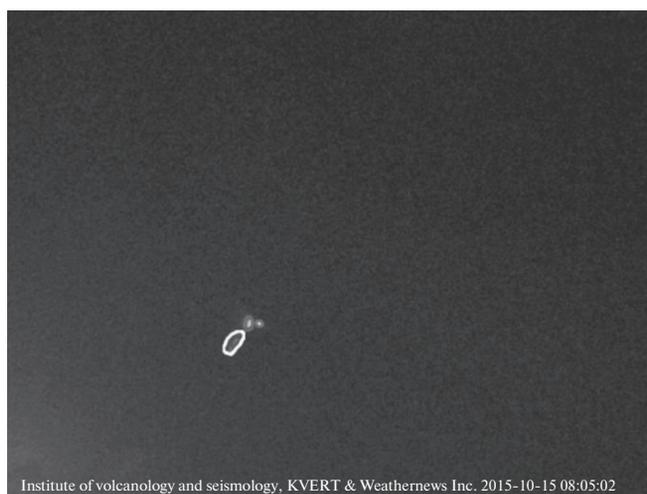


Рис. 6. Пример необнаруженных реальных аномалий (выделено жирным)

Заключение. В рамках исследований был разработан алгоритм обнаружения и классификации термальных аномалий на снимках вулканов, сделанных в ночное время суток в видимом и ближнем инфракрасном диапазонах. В качестве признаков рассматриваются: значение DoG-функции в центре, вытянутость аномалии, отношение периметра аномалии к минимально возможному периметру (сложность границы), асимметричность значений на краях, отношение перепада яркости центр-основание к значению яркости в центре, само значение яркости в центре и номер масштабного слоя DoG-пирамиды, на котором обнаружен максимум. При этом рассматриваются только те яркостные аномалии, которые находятся в области, покрытой контурами вулкана, либо касаются этой области. Описанные признаки позволяют классифицировать аномалии на термальные и иные яркостные аномалии. Для их классификации использовались три метода — наивный классификатор Байеса, SVM на основе радиальной базисной функции и классификатор K-means. Два последних классификатора показали очень близкий процент ошибки (~2%).

Результаты апробации алгоритма и созданных на его основе программных средств позволяют говорить о возможности их применения в задачах оперативного видеомониторинга за вулканической активностью на Камчатке [17].

СПИСОК ЛИТЕРАТУРЫ

1. *Sorokin A., Korolev S., Romanova I., Girina O., Urmanov I.* The Kamchatka Volcano Video Monitoring System // Proc. of 2016 6th Intern. Workshop on Computer Science and Engineering (WCSE 2016). Tokyo, Japan, 2016. P. 734–737.
2. *Камаев А.Н., Урманов И.П., Сорокин А.А., Карманов Д.А., Королев С.П.* Images Analysis for Automatic Volcano Visibility Estimation // Computer Optics. 2018. V. 42. № 1. P. 128–140.
3. *Урманов И.П., Камаев А.Н., Сорокин А.А., Королев С.П.* Оценка видимости и состояния вулканов по последовательностям изображений стационарных камер наблюдения // Вычислительные технологии. 2016. Т. 21. № 3. С. 80–90.
4. *Мельников Д.В., Маневич А.Г., Гурина О.А.* Количественные характеристики активности вулканов Камчатки по данным веб-камер // Тез. Докл. XVIII региональной конф., посвященной Дню вулканолога. Петропавловск-Камчатский: ИВиС ДВО РАН, 2015. С. 92–94.
5. *Rabal H.J., Braga J.R.A.* Dynamic Laser Speckle and Applications. Boca Raton: CRC Press, 2009.
6. *Olivo-Marin J.C.* Extraction of Spots in Biological Images Using Multiscale Products // Pattern Recognition. 2002. V. 35. № 9. P. 1989–1996.
7. *Wang F., Liu Y., Wu Ch., Chen X., Zeng K.* Spot Image Ablated by Femtosecond Laser Segmentation and Feature Clustering After Dimension Reduction Reconstruction // Optik. 2018. V. 164. P. 488–497.
8. *Andò B., Pecora E.* An Advanced Video-based System for Monitoring Active Volcanoes // Computers & Geosciences. 2006. V. 32. № 1. P. 85–91.
9. *Spampinato L., Calvari S., Oppenheimer C., Boschi E.* Volcano Surveillance Using Infrared Cameras // Earth-Science Reviews. 2011. V. 106. P. 63–91.
10. *Lowe D.G.* Distinctive Image Features from Scale-invariant Keypoints // Intern. J. of Computer Vision. 2004. V. 60. № 2. P. 91–110.
11. *Zhang H.* The Optimality of Naive Bayes // Proc. Seventeenth Intern. Florida Artificial Intelligence Research Society Conf. Miami Beach, Florida, USA: AAAI Press, 2004. P. 562–567.
12. *Shmilovici A.* Support Vector Machines // Data Mining and Knowledge Discovery Handbook. Boston, MA, USA: Springer. 2009. P. 257–276.
13. *Coates A., Ng A.Y.* Learning Feature Representations with K-Means // Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2012. V. 7700. P. 561–580.
14. *Sorokin A.A., Korolev S.P., Urmanov I.P., Verkhoturov A.I., Makogonov S.V., Shestakov N.V.* Software Platform for Observation Networks Instrumental Data Far Eastern Branch of the Russian Academy of Sciences // Proc. of Intern. Conf. on Computer Science and Environmental Engineering (CSEE 2015). DEStech Publications Inc. Beijing, 2015. P. 589–594.
15. *Vert J., Tsuda K., Schölkopf B.* A primer on Kernel Methods // Kernel Methods in Computational Biology. Cambridge, MA: MIT Press, 2004. V. 47. P. 35–70.
16. *Sorokin A.A., Makogonov S.V., Korolev S.P.* The Information Infrastructure for Collective Scientific Work in the Far East of Russia // Scientific and Technical Information Processing. 2017. V. 44. № 4. P. 302–304.
17. *Гордеев Е.И., Гурина О.А.* Вулканы и их опасность для авиации // Вестник Российской академии наук. 2014. Т. 84. № 2. С. 134–142.