

DOI: 10.17586/1023-5086-2022-89-04-40-51

УДК 535.36

Распознавание 3D объектов в однопозиционной системе лазерной локации методами интеллектуального анализа импульсных отражательных характеристик

ЛЕОНИД ВИТАЛЬЕВИЧ ЛАБУНЕЦ^{1✉}, АНДРЕЙ БОРИСОВИЧ БОРЗОВ²,
ИЛЬДАР МАРАТОВИЧ АХМЕТОВ³

Московский государственный технический университет им. Н.Э. Баумана, Москва, Россия

¹labunets@bmstu.ru; <https://orcid.org/0000-0002-9151-3420>

²borzov@rambler.ru; <https://orcid.org/0000-0003-037-0040>

³akhmetov.im@gmail.com; <https://orcid.org/0000-0003-1649-110X>

Аннотация

Предмет исследования. Предложена физически обоснованная экспертная модель исходных признаков для распознавания антропогенных 3D объектов в однопозиционной лазерной локационной системе. **Метод.** Модель основана на интеллектуальном анализе данных, полученных методом имитационного цифрового моделирования временных профилей импульсных отражательных характеристик объекта. Формирование информативных признаков реализовано методом главных компонент. **Основные результаты.** Продемонстрировано наличие и исследована кластерная структура пространства главных признаков. Машинными методами обучения идентифицированы параметры нескольких алгоритмов кластеризации и классификации 3D объектов и протестировано их качество в информативном пространстве. **Практическая значимость.** В хронологической последовательности представлены этапы решения задач кластеризации и классификации антропогенных объектов системой однопозиционной лазерной локации.

Ключевые слова: имитационное цифровое моделирование, импульсная эффективная площадь рассеяния 3D объекта, информативные признаки, алгоритмы кластеризации и классификации, машинные методы обучения

Ссылка для цитирования: Лабунец Л.В., Борзов А.Б., Ахметов И.М. Распознавание 3D объектов в однопозиционной системе лазерной локации методами интеллектуального анализа импульсных отражательных характеристик // Оптический журнал. 2022. Т. 89. № 4. С. 40–51. DOI: 10.17586/1023-5086-2022-89-04-40-51

Код OCIS: 070.5010.

ВВЕДЕНИЕ

Методология интеллектуального анализа данных (ИАД) и машинных методов обучения приобретает, в последнее время, ведущую роль в обосновании рациональной структуры и алгоритмов обработки входных сигналов оптико-электронных локационных систем [1, 2]. В частности, результаты ИАД имитационного цифрового моделирования временных профилей эффективной поверхности рас-

сеяния (ЭПР) и переходной характеристики (ПХ) [3] позволяют предложить семейство экспертных моделей в виде набора исходных признаков для последующего решения задач распознавания 3D объектов локации. Методика решения такого рода неформализованных задач опирается, как правило, на опыт и интуицию эксперта — высококвалифицированного специалиста в узкой предметной области. Недостатки указанного эвристического подхо-

да в значительной мере устраняют процедуры алгоритмического обнаружения закономерностей, скрытых в данных [4].

Целью данной работы является разработка методики формирования пространства информативных признаков для решения задач кластеризации и классификации на основе закономерностей, скрытых в характеристиках заметности антропогенных объектов локации в оптическом диапазоне спектра электромагнитных волн. Преимущество и новизну предлагаемой методики определяет реализация базы знаний в формате моделей временных профилей импульсной ЭПР или ПХ [3] объектов для нестационарных условий их облучения, при которых разрешение локатора по дальности меньше глубины сцены.

В рамках решаемой задачи интуитивно понятными и физически интерпретируемыми являются три типа исходных признаков, характеризующие размеры 3D объекта, его энергетические свойства и форму, трактуемую как меру сложности структуры временного профиля импульсной ЭПР или ПХ. В контексте методологии морфологического анализа временных рядов под формой понимают признаки общие для представителей фиксированного класса и инвариантные к условиям измерения сигналов [5]. В указанном смысле классическим и популярным на практике подходом к морфологическому анализу данных является, на наш взгляд, метод главных компонент, формирующий информативное пространство в базисе собственных векторов ковариационной матрицы исходных признаков формы [6], в частности для обучающей выборки временных профилей ПХ [7].

В качестве информационной основы формирования экспертной модели исходных признаков в данной работе выбран интеллектуальный анализ временного профиля импульсной ЭПР 3D объекта, измеряемой однопозиционной лазерной локационной системой.

ИМПУЛЬСНАЯ ЭПР 3D ОБЪЕКТА ЛОКАЦИИ

При некогерентном приёме, в приближении малых углов, когда объект облучается полнотью, а его размеры значительно меньше

расстояния L_S до источника и приёмника, временной профиль импульсной ЭПР

$$A_S(t|\alpha, \beta) = \int_{-R}^R \int_{-R}^R a(y, z) i_S \left\{ t - 2 \frac{L_S - x(y, z)}{c} \right\} dy dz, \quad 0 \leq t \leq T \quad (1)$$

представляет собой пространственно-временную свёртку распределения яркости $a(y, z)$ объекта в картинной плоскости YO_tZ (рис. 1) с зондирующим импульсом $i_S(t)$, нормированным условием $\max\{i_S(t)\}$ [1]. Здесь $x(y, z)$ — абсцисса облучённого facetsа в лучевой системе координат O_tXYZ ; c — скорость света; R — наибольший полярный радиус проекции объекта на картинную плоскость.

В дальнейшем там, где это не вызвано необходимостью, зависимость импульсной ЭПР от ракурса облучения-наблюдения $0 \leq \alpha \leq 2\pi$ и $-\pi/2 \leq \beta \leq \pi/2$ будем опускать.

При нестационарном облучении объекта разрешение локатора по дальности меньше глубины сцены, т.е. $ct_S/2 < x_{\max}(y, z) - x_{\min}(y, z)$. В этом режиме временной профиль импульсной ЭПР $A_S(t)$ является весьма информативным для решения задачи распознавания, поскольку для выбранного ракурса (α, β) :

- характеризует протяжённость объекта $T = 2\{x_{\max}(y, z) - x_{\min}(y, z)\}/c$ в единицах времени;

- демонстрирует зависимость «накопленной» по времени энергии отражённого сигнала




Рис. 1. Системы координат однопозиционной локации.

ла от глубины $t = 2\{x(y, z) - x_{\min}(y, z)\}/c$ текущего facets;

– содержит информацию о степени сложности геометрической конфигурации объекта [7].

Применение регуляризованной модели коэффициента яркости facets [8], а также адаптивного алгоритма численного интегрирования [2] для функции яркости $a(y, z)$ в выражении (1) позволили обнаружить на поверхности объекта локации участки преимущественно с диффузным или направленным рассеянием. Такой подход позволяет корректно идентифицировать как плавные, так и кратковременные, аномально большие всплески временного профиля импульсной ЭПР [3].

ЭКСПЕРТНАЯ МОДЕЛЬ ИСХОДНЫХ ПРИЗНАКОВ 3D ОБЪЕКТА

Аппаратными и программными средствами комплекса имитационного цифрового моделирования отражательных характеристик объектов [1] сформирована база данных для реализаций временных профилей импульсных ЭПР трёх космических объектов, а именно:

– крупноразмерного — транспортного космического корабля Space Shuttle, обозначаемого для краткости C1.

– среднеразмерного — космического аппарата (спутника) Lasr [9, 10] — C2;

– малоразмерного — космического аппарата (спутника) Imews [9, 10] — C3.

Обучающая выборка содержит $N_1 = 84$, $N_2 = 81$ и $N_3 = 82$ реализации временных профилей импульсных ЭПР соответственно объектов C1, C2 и C3. Значения углов, задающих ракурсы объектов, выбраны, как правило, с шагом 20° для $0 \leq \alpha \leq \pi$ и $-\pi/2 \leq \beta \leq \pi/2$. В результате экспертного анализа обучающей выборки предложено шесть исходных признаков, характеризующих для текущего ракурса:

1. Размер объекта $x(1) = T + t_s$, нс.

2. Энергетические свойства объекта, пропорциональные площади x_2 временного профиля ЭПР, его наибольшему значению x_3 и обобщённой амплитуде x_4 [1]

$$x(2) = \int_0^{T+t_s} A_S(v) dv, \text{ нс} \cdot \text{м}^2,$$

$$x(3) = \max \{A_S(v)\}, \text{ м}^2,$$

$$x(4) = \frac{1}{x(2)} \int_0^{T+t_s} A_S^2(v) dv, \text{ м}^2.$$

3. Геометрические критерии сложности формы, пропорциональные длине кривой $x(5)$ [11] временного профиля ЭПР и её кривизне $x(6)$,

$$x(5) = \sqrt{\sum_{m=1}^M \{A_S[m\Delta v] - A_S[(m-1)\Delta v]\}^2} + x(1)\Delta v, \quad M = x(1)/\Delta v,$$

$$x(6) = \sqrt{\sum_{m=2}^M \{A_S[m\Delta v] - 2A_S[(m-1)\Delta v] + A_S[(m-2)\Delta v]\}^2} + x(1)\Delta v,$$

где Δv — интервал дискретизации временного профиля импульсной ЭПР.

Предварительное исследование топологии обучающей выборки для указанных выше объектов локации методом Grand Tour [12] динамической визуализации многомерных данных подтвердило наличие кластерной структуры диаграмм рассеяния в шестимерном пространстве исходных признаков. Кроме того, кластер каждого из трёх объектов локации демонстрирует наличие аномальных значений признаков.

Статистический анализ исходных признаков

Аномалии существенно искажают выборочные оценки статистических характеристик исходных признаков $\mathbf{x} = \{x(1), \dots, x(6)\}^T$, которые, как известно, являются основой синтеза алгоритмов распознавания образов. Здесь и далее все векторы трактуют как векторы-столбцы. Значимые выбросы исключались из анализа характеристик положения и масштаба кластеров $k = 1, 2, 3$ трёх объектов C1, C2, C3 с помощью экспоненциально взвешенных

оценок (ЭВО) Л.Д. Мешалкина [13]. Робастные ЭВО векторов математических ожиданий $\mathbf{e}_k = \{e_k(1), \dots, e_k(6)\}^T$, и ковариационных матриц $\mathbf{B}_k = \{b_k(i, j)\}$, $i, j = 1, 2, \dots, 6$ для помеченных обучающих примеров $\mathbf{x}_{kn}$, $n = 1, 2, \dots, N_k$ получают в результате решения системы нелинейных уравнений [14, с. 75]

$$\begin{cases} \mathbf{e}_k = \sum_{n=1}^{N_k} q^\gamma \{D_k(n)\} \mathbf{x}_{kn} / \sum_{n=1}^{N_k} q^\gamma \{D_k(n)\} \\ \mathbf{C}_k = \sum_{n=1}^{N_k} q^\gamma \{D_k(n)\} \mathbf{x}_{kn} \mathbf{x}_{kn}^T / \sum_{n=1}^{N_k} q^\gamma \{D_k(n)\} \\ \mathbf{B}_k = (1 + \gamma) \{ \mathbf{C}_k - \mathbf{e}_k \mathbf{e}_k^T \} \end{cases} \quad (2)$$

методом последовательных приближений. Здесь $\gamma = 1/2$ — параметр устойчивости статистик к аномальным значениям; $q\{D_k(n)\} = \exp\{-D_k(n)/2\}$ — экспоненциальная весовая функция Л.Д. Мешалкина; $D_k(n) = (\mathbf{x}_{kn} - \mathbf{e}_k)^T \mathbf{B}_k^{-1} (\mathbf{x}_{kn} - \mathbf{e}_k)$ — метрика Махалабиса n -го примера в k -м кластере.

Кластеры объектов локации достаточно хорошо разнесены в пространстве исходных признаков (рис. 2). Свидетельством этого факта являются ЭВО векторов математических ожиданий $\mathbf{e}_k$ и средних квадратов отклонений $\mathbf{s}_k$ (табл. 1).




Рис. 2. Кластеры объектов локации в пространстве признаков $x(1)$, $x(2)$, $x(5)$.

Таблица 1. ЭВО векторов математических ожиданий и средних квадратов отклонений признаков

x	C1		C2		C3	
	e ₁	s ₁	e ₂	s ₂	e ₃	s ₃
x(1)	120,04	50,91	56,73	22,17	28,86	6,00
x(2)	29,99	12,93	11,20	5,75	2,55	0,37
x(3)	10,69	4,40	4,75	2,41	1,05	0,31
x(4)	3,51	1,57	1,68	0,97	0,44	0,16
x(5)	7,03	2,20	3,11	0,88	1,34	0,11
x(6)	3,60	0,55	2,06	0,19	1,24	0,11

Эффективными критериями информативности признака $x(i)$, $i = 1, 2, \dots, 6$ являются компоненты симметричной матрицы мер расстояний $\{\rho_{kl}(i)\}$ между его плотностями распределений вероятностей (ПРВ) $p_k\{x(i)\}$ и $p_l\{x(i)\}$ соответственно для k -го и l -го объектов в виде расстояний Бхатачария

$$\rho_{kl}(i) = -\ln \int \sqrt{p_k\{x(i)\} p_l\{x(i)\}} d\{x(i)\},$$


$$k = 1, 2, \quad l = 2, 3, \quad l > k. \quad (3)$$

Если распределения $p_k\{x(i)\}$ и $p_l\{x(i)\}$ i -го признака для k -го и l -го объектов совпадают, то $\rho_{kl}(i) \equiv 0$ в силу интегрируемости ПРВ с единицей. Иными словами, k -ый и l -ый объекты неразличимы по i -му признаку. Напротив, если ПРВ $p_k\{x(i)\}$ и $p_l\{x(i)\}$ практически не перекрываются, то в силу неравенства $p_k\{x(i)\} + p_l\{x(i)\} > 2\sqrt{p_k\{x(i)\} p_l\{x(i)\}}$ расстояние $\rho_{kl}(i) \rightarrow +\infty$.

Адекватной и популярной на практике является оценка ПРВ в виде гистограммы, сглаженной сдвигом (Average Shifted Histogram — ASH) [15]. Рисунок 3 демонстрирует ASH-оценки ПРВ для признаков $x(1)$ и $x(5)$, т.е. размера объекта и длины кривой временного профиля его ЭПР. В качестве модели нормированного окна данных для сглаживания классической гистограммы выбрано трижды взвешенное ядро Епанечникова. Оптимальное количество разрядных интервалов гистограммы выбиралось по правилу Фридмана–Дьякониса.

Таблица 2. Показатели информативности исходных признаков

i	1	2	3	4	5	6
$\rho_{12}(i)$	0,882	1,057	1,735	1,389	2,406	3,391
$\rho_{13}(i)$	3,324	23,026	7,260	3,911	23,026	23,026
$\rho_{23}(i)$	1,159	2,299	1,955	1,220	3,000	3,037
$\rho(i)$	3,629	23,165	7,7177	4,326	23,345	23,471
$h(i)$	0,3810	0,8729	1,1016	0,7530	1,3674	1,4482

Рис. 3. Оценки распределений признаков $x(1)$ (а) и $x(5)$ (б) объектов C1, C2, C3.

Рациональным агрегированным критерием информативности i -го признака является, на наш взгляд, норма Евклида

$$\rho(i) = \sqrt{\rho_{12}^2(i) + \rho_{13}^2(i) + \rho_{23}^2(i)} \quad (4)$$

верхней треугольной матрицы расстояний. Значения этого показателя информативности

для указанных выше признаков представлены в табл. 2.

Результаты анализа показывают, что наименее информативными признаками по критериям (3) и (4) расстояний Бхатачария между ПРВ являются размер объекта $x(1)$ и обобщённая амплитуда $x(4)$. Напротив, наиболее информативными признаками по указанным выше критериям являются площадь временного профиля ЭПР $x(2)$, длина его кривой $x(5)$ и кривизна профиля $x(6)$. Пограничное значение меры информативности демонстрирует наибольшее значение временного профиля ЭПР $x(3)$.

В монографии [4, с. 103] предложен альтернативный критерий оценки информативности i -го исходного признака, основанный на понятии его энтропии $H\{x(i)\}$ как меры различимости объектов анализа

$$H\{x(i)\} = P\{x(i)\} \log_2 [P\{x(i)\}] - \sum_{k=1}^3 p_k\{x(i)\} \log_2 [p_k\{x(i)\}],$$

$$P\{x(i)\} = \sum_{l=1}^3 p_l\{x(i)\}.$$

В рамках такого подхода агрегированным информационным критерием i -го признака является величина $h(i) = \log_2 3 - \int H\{x(i)\} dx(i)$. Результаты расчёта этого критерия, основанные на ASH-оценках ПРВ исходных признаков, сведены в финальную строку табл. 2. Наименее и наиболее информативными признаками по указанному критерию оказались $x(1)$ и $x(6)$ соответственно, что согласуется с ранжированием признаков по критерию расстояния Бхатачария.

Пространство информативных признаков

Диаграммы рассеяния (рис. 2) демонстрируют явно выраженные генеральные направления, что свидетельствует о наличии значимой корреляции исходных признаков. Классическим подходом к формированию информативных признаков с относительно низким уровнем корреляции является метод главных компонент [16]. Его информационную основу представляют робастные ЭВО (2) вектора математического ожидания $\mathbf{e} = \{e(1), \dots, e(6)\}^T$ и ковариационной матрицы $\mathbf{B} = \{b(i, j)\}$, $i, j = 1, 2, \dots, 6$, объединённой помеченной выборкой исходных признаков

$$\mathbf{x}_{11}, \mathbf{x}_{12}, \dots, \mathbf{x}_{1N_1}, \mathbf{x}_{21}, \mathbf{x}_{22}, \dots, \mathbf{x}_{2N_2}, \\ \mathbf{x}_{31}, \mathbf{x}_{32}, \dots, \mathbf{x}_{3N_3}$$

для классификации объектов C1, C2, C3.

Упорядоченная последовательность собственных значений матрицы $\mathbf{B}$ убывает предельно быстро. Первые два значения $\lambda(1) = 2538,6$ и $\lambda(2) = 157,8$ обеспечивают величину дисперсии ошибки реконструкции исходных данных $\{\lambda(1) + \lambda(2)\} / \{\lambda(1) + \dots + \lambda(6)\}$ не более 0,18%.

Иными словами, в шестимерном пространстве $\mathbf{x}$ ортогональные проекции указанных выше обучающих примеров $\mathbf{x}_{kn}$ на сигнальную гиперплоскость, заданную двумя главными собственными векторами $\mathbf{v}(1)$ и $\mathbf{v}(2)$ матрицы $\mathbf{B}$, содержат львиную долю полезной информации для распознавания объектов.

В терминах факторного анализа значения двух главных признаков $F(1)$ и $F(2)$ для выборки центрированных и нормированных обучающих примеров $\mathbf{y}_{11}, \mathbf{y}_{12}, \dots, \mathbf{y}_{1N_1}, \mathbf{y}_{21}, \mathbf{y}_{22}, \dots, \mathbf{y}_{2N_2}, \mathbf{y}_{31}, \mathbf{y}_{32}, \dots, \mathbf{y}_{3N_3}$ вычисляют по формулам

$$F_{kn}(j) = \mathbf{y}_{kn}^T \mathbf{v}(j) / \sqrt{\lambda(j)}, \quad j = 1, 2, \quad (5)$$

$$\mathbf{y}_{kn} = \{y_{kn}(1), \dots, y_{kn}(6)\}^T,$$

$$y_{kn}(i) = \{x_{kn}(i) - e(i)\} / s(i), \quad s(i) = \sqrt{b(i, i)}.$$

Параметры факторного анализа сведены в табл. 3.

Главные признаки рационально трактовать, как критерии, агрегирующие размер, энергетические свойства и форму объекта локации. Рисунок 4а иллюстрирует наличие явно вы-

Таблица 3. Параметры факторного анализа данных

x	e	s	v(1)	v(2)
x(1)	69,4630	49,9510	-0,9908	0,1340
x(2)	14,1821	13,0513	-0,1187	-0,9213
x(3)	5,6243	4,9451	-0,0517	-0,3037
x(4)	3,8620	2,6983	-0,0311	-0,1669
x(5)	2,2818	1,0546	-0,0161	-0,0503
x(6)	1,9769	1,73090	-0,0162	-0,1029




Рис. 4. Кластерная структура главных признаков для объектов C1, C2, C3. Диаграмма рассеяния (а), полигауссовская модель признаков (б).

раженной кластерной структуры диаграммы рассеяния главных признаков. Такого рода топологию достаточно адекватно описывает модель конечной смеси гауссовских распределений

$$p(\mathbf{F}) = \sum_{k=1}^3 q_k p_k(\mathbf{F}|\mathbf{E}_k, \mathbf{B}_k), \quad \sum_{k=1}^3 q_k = 1, \quad (6)$$

$$p_k(\mathbf{F}|\mathbf{E}_k, \mathbf{B}_k) = \frac{\exp\{-D(\mathbf{F}|\mathbf{E}_k, \mathbf{B}_k)/2\}}{2\pi\sigma_k(1)\sigma_k(2)\sqrt{1-r_k^2}},$$

представляющая собой методическую основу процедуры синтеза байесовского классификатора. Здесь $\mathbf{F} = \{F(1), F(2)\}^T$ — вектор главных признаков; q_k — априорная вероятность наблюдать k -ый объект; $\mathbf{E}_k = \{E_k(1), E_k(2)\}^T$ — вектор математического ожидания и ковариационная матрица

$$\mathbf{B}_k = \begin{bmatrix} \sigma_k^2(1) & r_k\sigma_k(1)\sigma_k(2) \\ r_k\sigma_k(1)\sigma_k(2) & \sigma_k^2(2) \end{bmatrix},$$

k -го кластера главных признаков, выраженная через средние квадратичные отклонения — $\sigma_k(1)$, $\sigma_k(2)$ и коэффициент корреляции — r_k .

Мерой расстояния для эллипсоидально симметричных распределений в полигауссовской модели (6) ПРВ кластеров $k = 1, 2, 3$ для объектов $C1, C2, C3$ является метрика Махаланобиса

$$D(\mathbf{F}|\mathbf{E}_k, \mathbf{B}_k) = \frac{f_k^2(1) - 2r_k f_k(1)f_k(2) + f_k^2(2)}{1 - r_k^2},$$

$$f_k(j) = \frac{F(j) - E_k(j)}{\sigma_k(j)}, \quad j = 1, 2.$$

Идентификацию указанных выше параметров $\theta = (q_1, q_2, q_3, \mathbf{E}_1, \mathbf{E}_2, \mathbf{E}_3, \mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3)$ ПРВ (6) по выборке (5) помеченных примеров $\mathbf{F}_{kn} = \{F_{kn}(1), F_{kn}(2)\}^T$ реализует ЕМ-алгоритм [16]. Применялась стандартная цель обучения модели (6) по критерию максимума выборочной оценки правдоподобия Фишера

$$\theta_{\text{opt}} = \arg \max_{\theta} \{L(\theta)\},$$

$$L(\theta) = \sum_{k=1}^3 \sum_{n=1}^{N_k} \ln \{p(\mathbf{F}_{kn}|\theta)\}.$$

Рациональными начальными приближениями для параметров модели конечной смеси эллипсоидально симметричных распределений являются выборочные средние

$$q_k[0] = \frac{N_k}{N}, \quad \mathbf{E}_k[0] = \frac{1}{N_k} \sum_{n=1}^{N_k} \mathbf{F}_{kn},$$

$$\mathbf{B}_k[0] = \frac{1}{N_k} \sum_{n=1}^{N_k} \mathbf{F}_{kn} \mathbf{F}_{kn}^T - \mathbf{E}_{kn}[0] \mathbf{E}_{kn}^T[0].$$

На E шаге I -ой итерации обучения ЕМ-алгоритм взвешивает данные, вычисляя элементы матрицы $\mathbf{Pr}[I]$ апостериорных вероятностей

$$Pr_{kn}[I] = \frac{q_k[I-1] p_k(\mathbf{F}_{kn}|\mathbf{E}_k[I-1], \mathbf{B}_k[I-1])}{p(\mathbf{F}_{kn}|\theta[I-1])},$$

$$I = 1, 2, \dots, \quad (7)$$

ассоциации наблюдаемого примера $\mathbf{F}_{kn}$ с кластерами трёх объектов $C1, C2, C3$, где $k = 1, 2, 3$; $n = 1, \dots, N_1, N_1 + 1, \dots, N_1 + N_2, N_1 + N_2 + 1, \dots, N_1 + N_2 + N_3$. Иными словами, элементы этой матрицы приобретают смысл оценок степени надёжности, с которыми относят наблюдение $\mathbf{F}_{kn}$ к каждому из классов.

На M шаге I -ой итерации обучения ЕМ-алгоритм уточняет максимально правдоподобные оценки параметров ПРВ (6)

$$\tilde{N}_k[I] = \sum_{n=1}^N Pr_{kn}[I], \quad q_k[I] = \frac{\tilde{N}_k[I]}{N},$$

$$\mathbf{E}_k[I] = \frac{1}{\tilde{N}_k[I]} \sum_{n=1}^N Pr_{kn}[I] \mathbf{F}_{kn},$$

$$\mathbf{B}_k[I] = \frac{1}{\tilde{N}_k[I]} \sum_{n=1}^N Pr_{kn}[I] \mathbf{F}_{kn} \mathbf{F}_{kn}^T - \mathbf{E}_{kn}[I] \mathbf{E}_{kn}^T[I],$$

где $N = N_1 + N_2 + N_3$ — объём объединённой выборки обучающих примеров (5); $\tilde{N}_k[I]$ — апостериорный объём наблюдений $\mathbf{F}_{kn}$, ассоциированных с k -ым кластером.

Хронологически последовательные приближения E шага и M шага повторяют до тех пор, пока имеют место значимые различия между оценками параметров модели (6) на текущей I

Таблица 4. Максимально правдоподобные оценки параметров полигауссовской модели ПРВ главных признаков

k	$\tilde{N}_k$	q_k	$E_k(1)$	$E_k(2)$	$\sigma_k(1)$	$\sigma_k(2)$	r_k
1	83,2690	0,3371	0,4417	0,7046	0,1811	0,1523	−0,2502
2	89,7294	0,3633	0,7872	0,9021	0,0768	0,0557	−0,3273
3	74,0016	0,2996	0,9283	0,9854	0,0272	0,0041	−0,2666




Рис. 5. Мягкая байесовская классификация объектов C1, C2, C3. Степени принадлежности объектов к классам (а), визуализация результатов классификации (б).

и предыдущей ($I - 1$) итерациях ЕМ-алгоритма. Для $N = 247$ обучающих примеров в пространстве информативных признаков $\mathbf{F} = \{F(1), F(2)\}^T$ сходимость ЕМ-алгоритма достигнута за 14 итераций. Финальные максимально правдоподобные оценки параметров полигауссовской модели (6) сведены в табл. 4.

Эквипотенциальные линии, соответствующие значениям расстояний Махаланобиса $\sqrt{D(\mathbf{F} | \mathbf{E}_k, \mathbf{B}_k)} = 1, 2, 3$, представлены тройками эллипсоидов на рис. 4б для трёх кластеров $k = 1, 2, 3$ объектов C1, C2, C3.

Распознавание объектов локации

Важно отметить, что матрица апостериорных вероятностей (7) выполняет мягкую байесовскую кластеризацию примеров объединённой обучающей выборки. Не отвергая ни одну из гипотез о принадлежности непомеченного наблюдения $\mathbf{F}_n$ к кластерам $k = 1, 2, 3$ из

предложенного списка, элементы n -го столбца $(Pr_{1n}, Pr_{2n}, Pr_{3n})^T$ матрицы (7) указывают степени принадлежности текущего наблюдения к объектам C1 или C2 или C3 (рис. 5а). Иными словами, байесовский подход позволяет алгоритму распознавания объектов адекватно функционировать в нестационарной среде, обновляя оценки апостериорных вероятностей по мере поступления новых измерений. Такого рода мягкую байесовскую классификацию иллюстрирует рис. 5б.

Точки диаграмм рассеяния кластеров трёх объектов ортогонально спроецированы на направление собственного вектора, соответствующего наибольшему собственному значению ковариационной матрицы объединённой выборки обучающих примеров в пространстве главных признаков. На рисунке эта ось проходит через центр группировки данных. Цвета маркеров для проекций точек диаграмм

Таблица 5. Вероятности ошибок распознавания объектов

Ошибка	C1		C2		C3	
	ЕМ	DBSCAN	ЕМ	DBSCAN	ЕМ	DBSCAN
I рода	0,0357	0,0357	0	0	0,0976	0,0854
II рода	0	0	0,1196	0,1099	0	0

рассеяния указывают на возможность принадлежности помеченных наблюдений F_{kn} к кластерам $k = 1, 2, 3$ из предложенного списка со значимыми апостериорными вероятностями $Pr_{kn} \geq 0,00000001$, где $Pr_{1n} + Pr_{2n} + Pr_{3n} \equiv 1$. Окончательное решение об обнаружении конкретного объекта принимают по правилу победителя, т.е. выбирают класс $k_{\text{opt}}(n) = \max_{1 \leq k \leq 3} \{Pr_{kn}\}$ с наиболь-

шим значением апостериорной вероятности.

Из $N_1 = 84$ наблюдений, фактически принадлежащих объекту C1, 81 обучающий пример с высокой апостериорной вероятностью $Pr_{1n} \geq 0,9879$ отнесены к первому кластеру (рис. 5а). Три наблюдения за объектом C1 с номерами $n = 36; 52; 80$ ошибочно отнесены к кластеру объекта C2 с наибольшими апостериорными вероятностями $Pr_{2n} = 0,5037; 0,7246; 0,9945$ соответственно. Таким образом, выборочные оценки вероятностей ложной тревоги и пропуска объекта составляют величины 0 и $3/84 = 0,0357$ соответственно.

Из $N_3 = 82$ наблюдений, фактически принадлежащих объекту C3, 74 примера с высокой апостериорной вероятностью $Pr_{3n} \geq 0,8487$ отнесены к третьему кластеру (рис. 5а). Восемь наблюдений за объектом C3 с номерами $n = 170, 171; 172, 180; 241; 242; 243; 244$ ошибочно отнесены к кластеру объекта C2 с наибольшими апостериорными вероятностями $Pr_{2n} = 0,9952; 0,9968; 0,7076; 0,9621; 0,9969; 0,9933; 0,9952; 0,9958$ соответственно. Таким образом, выборочные оценки вероятностей ложной тревоги и пропуска объекта составляют величины 0 и $8/82 = 0,0976$ соответственно.

Все наблюдения $N_2 = 81$, фактически принадлежащие объекту C2, классифицированы по правилу победителя верно с высокой апостериорной вероятностью $Pr_{2n} \geq 0,8249$ (рис. 5а). Однако, как указано выше, ко второму кластеру ошибочно отнесены три на-

блюдения за объектом C1 и восемь наблюдений за объектом C3. Таким образом, выборочные оценки вероятностей ложной тревоги и пропуска объекта составляют величины $11/92 = 0,1196$ и 0 соответственно.

Вероятности ошибок I-рода (пропуска объекта) и II-рода (ложной тревоги) жёсткой байесовской классификации выборки обучающих примеров, реализованной с помощью ЕМ-алгоритма, сведены в табл. 5.

Популярной на практике методикой анализа надёжности распознавания образов является сопоставление результатов функционирования альтернативных алгоритмов классификации и кластеризации объектов. Наряду с ЕМ-алгоритмом, весьма эффективным инструментом кластеризации наблюдений является процедура DBSCAN [17]. Параметрами этой процедуры являются метрика расстояния, радиус сферы ближайших соседей e и минимальное количество наблюдений minPts , которые образуют плотную область. DBSCAN реализует кластеризацию наблюдений по принципу «один против всех».

В пространстве информативных признаков $\{F(1), F(2)\}$ применяют метрику расстояния Евклида. По этой причине значимая вариация плотности наблюдений (рис. 4а) не позволяет выбрать оптимальную для различных кластеров комбинацию параметров e и minPts . С учётом этой особенности алгоритма DBSCAN адекватную кластеризацию немеченной выборки центрированных и нормированных обучающих примеров $Y_1, Y_2, \dots, Y_{N_1+N_2+N_3}$ выполняют в два этапа.

На первом этапе, реализованном с параметрами $e = 0,1$ и $\text{minPts} = 8$, из данных исключено 81 наблюдение, отнесённое к объекту C1. Три наблюдения с номерами $n = 36; 52; 80$ (из $N_1 = 84$ фактически принадлежащих первому кластеру) ошибочно отнесены к кластеру объекта C2. На втором этапе, реализованном с параметрами $e = 0,022$ и $\text{minPts} = 10$,




Рис. 6. Робастные дискриминантные границы SVM-классификации данных.

из оставшихся $166 = 247 - 81$ данных исключено 75 наблюдений, отнесённых к объекту C3. Семь наблюдений с номерами $n = 170; 171; 172; 173; 241; 243; 244$ (из $N_3 = 82$ фактически принадлежащих третьему кластеру) ошибочно отнесены к кластеру объекта C2. Все наблюдения $N_2 = 81$, фактически принадлежащие объекту C2, идентифицированы верно. Однако, как указано выше, ко второму кластеру ошибочно отнесены три наблюдения за объектом C1 и семь наблюдений за объектом C3. Вероятности ошибок I-рода и II-рода кластеризации выборки обучающих примеров, реализованной с помощью алгоритма DBSCAN, сведены в табл. 5.

Для кластеров, сформированных алгоритмом DBSCAN, рационально синтезировать робастные модели дискриминантных границ, обладающих свойством обобщения. С этой целью применялась полиномиальная машина опорных векторов (Support Vector Machine — SVM) [18], обеспечивающая максимально широкие разделяющие полосы между классами.

По результатам кластеризации алгоритма DBSCAN текущему n -му примеру F_{kn} присваивают метку $\delta_{kn} = +1$, если он принадлежит k -му классу. В противном случае присваивают метку $\delta_{kn} = -1$. По принципу классификации «один против одного» SVM-сеть син-

тезирует дискриминантные функции $d_{kl}\{F\}$ для всех пар кластеров $k = 1, 2; l = 2, 3; k < l$. Классификация без ошибок предполагает положительные значения функций $d_{kl}\{F_{kn}\} > 0$, $l = 1, 2, 3, l \neq k$. Работу SVM-классификатора описывает система неравенств:

$$\begin{cases} \delta_{12}d_{12}\{F_{1n}\} > 0, \delta_{13}d_{13}\{F_{1n}\} > 0, \text{ для } C1 \\ \delta_{12}d_{12}\{F_{2n}\} < 0, \delta_{23}d_{23}\{F_{2n}\} > 0, \text{ для } C2. \\ \delta_{13}d_{13}\{F_{3n}\} < 0, \delta_{23}d_{23}\{F_{3n}\} < 0, \text{ для } C3 \end{cases}$$

Дискриминантные границы обученной SVM-сети минимизируют количество ошибочных классификаций, если таковые появятся для новых данных. Результаты представлены на рис. 6. Идентифицированные машиной наиболее сложные для классификации опорные вектора отмечены маркером «круг».

ЗАКЛЮЧЕНИЕ

В работе представлены хронологически последовательные этапы решения задачи распознавания 3D объектов однопозиционной системой лазерной локации. С помощью аппаратно-программного комплекса имитационного цифрового моделирования временных профилей импульсной ЭПР объектов сформирована база данных обучающих примеров. Предложена экспертная модель пространства исходных признаков, характеризующих размеры, энергетические свойства и критерии формы 3D объектов. Получены выборочные оценки основных статистик исходных признаков, робастные к аномальным значениям обучающих примеров. Исследованы кластерная структура и меры информативности исходных признаков, реализовано их отображение на пространство информативных признаков методом главных компонент.

Проанализированы альтернативные алгоритмы классификации и кластеризации наблюдений за объектами и меры их качества распознавания. В частности, на основе модели конечной смеси стандартных распределений информативных признаков представлена методика синтеза байесовского классификатора объектов и получены его оптимальные параметры с помощью ЕМ-алгоритма. Продемонстрирована эффективность алгорит-

ма DBSCAN кластеризации обучающих примеров в пространстве информативных признаков. По результатам кластеризации получены оптимальные параметры квадратичных дискриминантных границ SVM-классификатора.

Продемонстрирована возможность распознавания крупноразмерного, среднеразмерного и малоразмерного объектов в результате интеллектуального анализа временного профиля импульсной ЭПР в однопозиционной лазерной локации.

СПИСОК ИСТОЧНИКОВ

1. Лабунец Л.В. Цифровые модели изображений целей и реализаций сигналов в оптических локационных системах: Учеб. пособие. М.: Изд-во МГТУ им. Н.Э. Баумана, 2007. 216 с.
2. Лабунец Л.В. Цифровое моделирование оптических отражательных характеристик целей в режиме реального времени: Учеб. пособие. М.: Изд-во МГТУ им. Н.Э. Баумана, 2013. 211 с.
3. Лабунец Л.В., Борзов А.Б., Ахметов И.М. Модели реального времени импульсных отражательных характеристик 3D объектов в однопозиционной системе лазерной локации // Оптический журнал. 2020. Т. 87. № 9. С. 12–23.
L.V. Labunets, A.B. Borzov, I.M. Akhmetov. Real-time models of pulsed reflectance profiles of 3D objects in a monostatic laser location system // Journal of Optical Technology. 2020. V. 87. No. 9. P. 513–520.
4. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. Новосибирск: ИМ СО РАН, 1999. 270 с.
5. Куличков С.Н., Чуличков А.И., Демин Д.С. Морфологический анализ инфразвуковых сигналов в акустике. М.: Новый Акрополь, 2010. 132 с.
6. Чуличков А.И., Цыбульская Н.Д., Куличков С.Н. Исследование возможности классификации инфразвуковых сигналов методами проверки статистических гипотез // Вестник Московского университета. Серия 3. Физика. Астрономия. 2012. № 2. С. 20–22.
7. Лабунец Л.В. Цифровая обработка переходных характеристик 3D объектов в однопозиционной системе оптической локации // Радиотехника и электроника. 2002. Т. 47. № 4. С. 452–460.
L.V. Labunets, Digital processing of transient responses of 3D objects in a monostatic optical radar system // Journal of Communications Technology and Electronics. 2002. V. 47. No. 4. P. 405–412. ISSN 1064–2269.
8. Лабунец Л.В., Борзов А.Б., Ахметов И.М. Регуляризованная параметрическая модель индикатрисы коэффициента яркости шероховатой поверхности // Оптический журнал. 2019. Т. 86. № 10. С. 20–29.
Labunets L.V., Borzov A.B., Akhmetov I.M. Regularized parametric model of the angular distribution of the brightness factor of a rough surface // Journal of Optical Technology. 2019. V. 86. No. 10. P. 618–626. <https://doi.org/10.1364/JOT.86.000618>.
9. Беляков А.М., Палагин Е.П., Ханцеверов Ф.Р. Советская Военная энциклопедия / Институт военной истории Министерства обороны СССР. М.: Воениздат, 1976. Т. 4: Многоцелевые космические аппараты. С. 386, 387.
10. Андронов А., Шевров Р. Американские космические системы видовой разведки // Зарубежное военное обозрение. М.: Красная звезда, 1995. № 2. С. 39–43.
11. Gustavo Batista, Eamonn J. Keogh, Oben Moses Tataw, Vincius M.A. de Souza, CID: an efficient complexity-invariant distance for time series // Data Mining and Knowledge Discovery. 2014. V. 28. No. 3. P. 634–669.
12. Buja A., Cook D., Asimov D., Hurley C.B. Theory and computational methods for dynamic projections in high-dimensional data visualizations / A monograph on rendering techniques, mathematics, and algorithms for tours and related methods. 1996. 67 pp. URL: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.49.9039&rep=rep1&type=pdf>
13. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Исследование зависимостей: Справ. изд. М.: Финансы и статистика, 1985. 487 с.
14. Шурыгин А.М. Прикладная стохастика: робастность, оценивание, прогноз. М.: Финансы и статистика, 2000. 224 с.
15. Scott D.W. Multivariate density estimation: Theory, practice, and visualization. N.-Y.: John Wiley & Sons, Inc, 1992. 317 p.
16. Айвазян С.А. Енюков И.С. Мешалкин Л.Д. Прикладная статистика: Классификация и снижение размерности: Справ. изд. / Под ред. Айвазяна С.А. М.: Финансы и статистика, 1989. 607 с.

17. Martin Ester, Hans-Peter Kriegel, Jörg Sander, Xiaowei Xu. A density-based algorithm for discovering clusters in large spatial databases with noise // Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96) / Evangelos Simoudis, Jiawei Han, Usama M. Fayyad. AAAI Press, 1996. P. 226–231.
18. Хайкин С. Нейронные сети: полный курс. 2-е изд. М.: ИД «Вильямс». 2006. 1104 с.
Simon S. Haykin, Neural networks. A Comprehensive Foundation. 2nd ed. N.Y.: Prentice Hall, 1999. 842 p.

АВТОРЫ

Леонид Витальевич Лабунец — доктор технических наук, профессор, Московский государственный технический университет им. Н.Э. Баумана, 105005, Москва, Россия; профессор, АНО ВО «Российский новый университет» (РосНОУ), 105005, Москва, Россия; Scopus ID: 66025157600; <https://orcid.org/0000-0002-9151-3420>; labunets@bmstu.ru

Андрей Борисович Борзов — доктор технических наук, профессор, заведующий кафедрой, Московский государственный технический университет им. Н.Э. Баумана, 105005, Москва, Россия; Scopus ID: 55861205300; <https://orcid.org/0000-0003-037-0040>; borzov@rambler.ru

Ильдар Маратович Ахметов — аспирант, Московский государственный технический университет им. Н.Э. Баумана, 105005, Москва, Россия; Scopus ID: 57212380698; <https://orcid.org/0000-0003-1649-110X>; akhmetov.im@gmail.com

AUTHORS

Leonid V. Labunets — Doctor of Technical Sciences, Professor, Bauman Moscow State Technical University, 105005, Moscow, Russia; Professor, Russian New University, 105005, Moscow, Russia; Scopus ID: 66025157600; <https://orcid.org/0000-0002-9151-3420>; labunets@bmstu.ru

Andrey B. Borzov — Doctor of Technical Sciences, Professor, Head of the Department, Bauman Moscow State Technical University, 105005, Moscow, Russia; Scopus ID: 55861205300; <https://orcid.org/0000-0003-037-0040>; borzov@rambler.ru

Ildar M. Akhmetov — Postgraduate, Bauman Moscow State Technical University, 105005, Moscow, Russia; Scopus ID: 57212380698; <https://orcid.org/0000-0003-1649-110X>; akhmetov.im@gmail.com