

СВЯЗНОСТЬ ОБЪЕКТОВ КЛАССОВ И ЕЕ ВЛИЯНИЕ НА ОБОБЩАЮЩУЮ СПОСОБНОСТЬ АЛГОРИТМОВ

Турсунмуротов Д.Х.

*Старший преподаватель кафедры технологий
программирования факультета программной инженерии
Ташкентского университета информационных технологий
имени Мухаммада аль-Хорезми*

Annotation: Рассматриваются методы анализа структуры отношений классифицированных объектов в пространстве разнотипных признаков. Оценка отношений проводилось по мере компактности и через визуальное представления объектов на плоскости.

Ключевые слова: Компактность, визуализация, DBSCAN.

Для оценки структуры обучающей выборки разработаны различные методы, принципы их работы существенно отличаются друг от друга. Основные идеи, приводимого ниже метода, изложены в [4]. Целями разбиения объектов классов на непересекающиеся группы являются:

- вычисление и анализ значений компактности объектов классов и выборки в целом;
- поиск минимального покрытия обучающей выборки объектами–эталонами.

Рассматривается задача распознавания в стандартной постановке. Считается, что задано множество $E_0 = \{S_1, \dots, S_m\}$ объектов, разделённое на l ($l > 2$) непересекающихся подмножеств (классов) K_1, \dots, K_l , $E_0 = \bigcup_{i=1}^l K_i$. Описание объектов производится с помощью набора из n разнотипных признаков $X(n) = (x_1, \dots, x_n)$, ξ из которых измеряются в интервальных шкалах, $(n - \xi)$ – в номинальной. На множестве объектов E_0 задана метрика $\rho(x, y)$.

Обозначим через $L(E_0, \rho)$ – подмножество граничных объектов классов, определяемое на E_0 по метрике $\rho(x, y)$. Объекты $S_i, S_j \in K_t$, $t = 1, \dots, l$ считаются связанными между собой ($S_i \leftrightarrow S_j$), если $\{S \in L(E_0, \rho) | \rho(S, S_i) < r_i \text{ и } \rho(S, S_j) < r_j\} \neq \emptyset$, где r_i (r_j) – расстояние до ближайшего от S_i (S_j) объекта из CK_t ($CK_t = E_0 \setminus K_t$) по метрике $\rho(x, y)$.

Множество $G_{tv} = \{S_{v_1}, \dots, S_{v_c}\}$, $c \geq 2$, $G_{tv} \subset K_t$, $v < |K_t|$ представляет область (группу) со связанными объектами в классе K_t , если для любых $S_{v_i}, S_{v_j} \in G_{tv}$ существует путь $S_{v_i} \leftrightarrow S_{v_k} \leftrightarrow \dots \leftrightarrow S_{v_j}$. Объект $S_i \in K_t$, $t = 1, \dots, l$ принадлежит группе из одного элемента и считается несвязанным, если не существует пути $S_i \leftrightarrow S_j$ ни

для одного объекта $S_j \neq S_i$ и $S_j \in K_t$. Требуется определить минимальное число непересекающихся групп из связанных и несвязанных объектов по каждому классу K_t , $t=1, \dots, l$.

При определении минимального числа групп из связанных и несвязанных объектов классов используется $L(E_0, \rho)$ – подмножество граничных объектов (оболочка) классов по заданной метрике ρ и описание объектов в новом пространстве из бинарных признаков. Для выделения оболочки классов для каждого $S_i \in K_t$, $t=1, \dots, l$ строится упорядоченная по $\rho(x, y)$ последовательность

$$S_{i_0}, S_{i_1}, \dots, S_{i_{m-1}}, S_i = S_{i_0}. \quad (1)$$

Пусть $S_{i_\beta} \in CK_t$ ближайший к S_i объект из (1) не входящий в класс K_t . Обозначим через $O(S_i)$ окрестность радиуса $r_i = \rho(S_i, S_{i_\beta})$ с центром в S_i , включающую все объекты, для которых $\rho(S_i, S_{i_\tau}) < r_i$, $\tau = 1, \dots, \beta-1$. В $O(S_i)$ всегда существует непустое подмножество объектов

$$\Delta_i = \left\{ S_{i_\alpha} \in O(S_i) \mid \rho(S_{i_\beta}, S_{i_\alpha}) = \min_{S_{i_\tau} \in O(S_i)} \rho(S_{i_\beta}, S_{i_\tau}) \right\}.$$

(2)

По (2) принадлежность объектов к оболочке классов определяется как

$$L(E_0, \rho) = \bigcup_{i=1}^m \Delta_i.$$

Множество объектов оболочки из $K_t \cap L(E_0, \rho)$ обозначим как $L_t(E_0, \rho) = \{S^1, \dots, S^\pi\}$, $\pi \geq 1$. Значение $\pi = 1$ однозначно определяет вхождение всех объектов класса в одну группу. При $\pi \geq 2$ преобразуем описание каждого объекта $S_i \in K_t$ в $S_i = (y_{i1}, \dots, y_{i\pi})$, где

$$y_{ij} = \begin{cases} 1, & \rho(S_i, S^j) < r_i, \\ 0, & \rho(S_i, S^j) \geq r_i. \end{cases}$$

(3)

Пусть по (3) получено описание объектов класса K_t в новом (бинарном) признаковом пространстве, $\Omega = K_t$, θ – число непересекающихся между собой групп объектов, $S_\mu \vee S_\eta$, $S_\mu \wedge S_\eta$ – соответственно операции дизъюнкции и конъюнкции по бинарным признакам объектов $S_\mu, S_\eta \in K_t$. Пошаговое выполнение алгоритма разбиения объектов K_t на непересекающиеся группы G_1, \dots, G_θ таково.

Шаг 1: $\theta = 0$;

Шаг 2: Выделить объект $S \in \Omega$, $\theta = \theta + 1$, $Z = S$, $G_\theta = \emptyset$;

Шаг 3: **Выполнять** Выбор $S \in \Omega$ и $S \wedge Z = \text{true}$, $\Omega = \Omega \setminus S$, $G_\theta = G_\theta \cup S$, $Z = Z \vee S$ пока $\{S \in \Omega \mid S \wedge Z = \text{true}\} \neq \emptyset$;

Шаг 4: Если $\Omega \neq \emptyset$, то идти 2;

Шаг 5: Конец.

Результаты разделения объектов класса на непересекающиеся группы предлагаются оценивать по алгоритму в [2] использованием специальных мер компактности. Измерение компактности служат инструментом анализа изменений в структуре классов при удалении шумовых объектов.

Предлагаются оценку компактности структуры отношений объектов измерять в (0;1]. Существуют классические алгоритмы группировки объектов, в том числе алгоритм DBSCAN. Этот алгоритм кластеризации на основе плотности: для набора точек в заданном пространстве алгоритм группирует близко расположенные точки, отмечая как выбросы изолированные точки в области низкой плотности (включая дальних ближайших соседей). DBSCAN — один из наиболее часто используемых алгоритмов кластеризации. Если в пределах поискового расстояния от конкретной точки не найдено минимальное количество объектов кластера, то эта точка помечается как основная и включается в кластер вместе со всеми точками. В выборке [3] мы разделяем объекты на группы с помощью алгоритма DBSCAN и визуализируем их помощью алгоритма [5]. Алгоритм разделил выборку на две группы на 19 и 81 объектов.

Представление объектов в новом (двумерном) признаковом пространстве показано на рис. 1 и рис. 2. Мы можем визуализировать представление разных групп путем изменения значений радиусов в алгоритме DBSACAN. В табл. 1 приведены значения компактности для DBSCAN и связанности по системе пересекающихся интервалов.

Рис1. Визуализация разделения на две группы объектов в DBSCAN из 19 и 81 объектов





Рис2. Визуализация двух групп в DBSCAN в соотношении 72 и 28



Мы можем сравнить эффективность использования двух отношений объектов по мере компактности (см. табл. 1).

Таблица 1. Сравнение отношений по мере компактности оценок

Отношение	Количество групп	Компактность
плотности	2	0.5678
связанности	4	0.8116

на графике ниже мы видим, что метод связанности объектов по пересекающимся гипершарам дает более высокую компактность, чем метод DBSCAN по плотности распределения.



Литература:

[1] Загоруйко Н.Г, Кутненко О.А . , Зырянов А . О . , Леванов Д.А Обучение распознаванию образов без переобучения // Машинное обучение и анализ данных, Т. 1 . – № 7. – 2014. – С . 89 1–90 1 .

[2] Ignatyev N. A . Structure Choice for Relations between Objects in Metric

Classification Algorithms // Pattern Recognition and Image Analysis, V. 28. – № 4. – 2018. – P. 590–597.

[3] Убайдуллаева Р.Т. Саморефлексия как субъектно-практическая методология социологии: // Автореферат диссертации доктора по социологическим наукам, Ташкент. –2019. – С. 11–28.

[4] Ignatyev N. A . On Nonlinear Transformations of Features Based on the Functions of Objects Belonging to Classes // Pattern Recognition and Image Analysis, V. 31 . – № 2. – 2021 . – P. 197–204.

[5] Сайдов Д.Ю. Информационные модели на основе нелинейных преобразований признакового пространства в задачах распознавания// Дисс. . . . доктора философии (PhD) по Физико - математическим наукам, Ташкент – 2017. – 93. с.

[6] Зиновьев А .Ю. Визуализация многомерных данных // Красноярск, Изд. КГТУ, – 2000. – 1 80 . с .