

## Многомерная математическая модель и геометрический метод классификации объектов

*Р.Р. Агафонова, И.М. Габдуллин, А.В. Мингалев*

*АО «НПО ГИПО»*

**Аннотация:** Представлены математическая модель и геометрический метод классификации объектов по изображению, которые обеспечивают повышение точности классификации объектов за счет фильтрации шумовых объектов.

**Ключевые слова:** обработка изображений, распознавание объектов, распознавание образов, идентификация объектов, классификация.

В настоящее время цифровая обработка изображений применяется во всех областях науки и техники, в том числе, в тепловидении [1-3]. Одной из актуальных задач при автоматизированной обработке изображений является распознавание и классификация объектов [4-6].

В данной статье описан разработанный авторами метод классификации объектов, основанный на предложенной математической модели, которая представляет собой  $M$  замкнутых областей, каждая из которых соответствует одному классу. Замкнутые области строятся в  $n$ -мерном пространстве признаков [7,8].

За счет замкнутости областей в решение задачи классификации введено новое понятие «оценка степени схожести», которое позволяет одновременно классифицировать и отфильтровывать объекты [9,10].

Особенностью разработанной математической модели является повышение точности классификации объектов за счет обеспечения фильтрации шумовых объектов. Такая фильтрация достигается тем, что математическая модель содержит  $(N+1)$  классов, из которых  $N$  – количество предварительно заданных классов, для которых представлена обучающая выборка, а для  $(N+1)$  -ого класса не может быть представлена обучающая выборка, так как к этому классу относится «шум».

Принадлежность к  $(N+1)$ -ому классу определяют в указанной модели посредством того, что исследуемый объект не принадлежит ни к одному из  $N$  предварительно заданных классов на основе оценки степени схожести по их физическим признакам.

Для работы с созданной математической моделью в  $n$ -мерном пространстве признаков осуществляется проверка попадания исследуемого объекта в один из классов или за пределы всех классов по его координатам в  $n$ -мерном пространстве признаков (вектор координат).

Метод построения границы каждого класса для предлагаемой математической модели состоит в следующем:

1. Строится выпуклая оболочка класса, которая состоит из точек  $b_i = (x_1^{b_i}, x_2^{b_i}, \dots, x_n^{b_i})$ ,  $i = \overline{1, F}$ , где  $F$  – количество точек, образующих выпуклую оболочку. Выпуклая оболочка класса строится методом Грэхема.

2. Определяется центральная точка класса (барицентр)  $C = (x_1^c, x_2^c, \dots, x_n^c)$ . Далее область, занимаемая классом в  $n$ -мерном пространстве признаков, разделяется на  $F$  секторов. Разделение на секторы происходит за счет соединения центральной точки  $C$  с каждой точкой выпуклой оболочки.

3. После разделения на секторы, в каждом из них точки выпуклой оболочки преобразуют, исходя из плотности распределения обучающей выборки предварительно заданного класса, в точки расширенной выпуклой оболочки класса  $\hat{b}_i = (x_1^{\hat{b}_i}, x_2^{\hat{b}_i}, \dots, x_n^{\hat{b}_i})$ ,  $i = \overline{1, F}$ , где  $F$  – количество точек, образующих расширенную выпуклую оболочку класса, по формуле:

$$\begin{cases} x_1^{\hat{b}_i} = x_1^c + \frac{(x_1^c - x_1^{b_i}) * \rho(c, \hat{b}_i)}{\rho(c, b_1)} \\ x_2^{\hat{b}_i} = x_2^c + \frac{(x_2^c - x_2^{b_i}) * \rho(c, \hat{b}_i)}{\rho(c, b_2)}, \\ \dots \\ x_n^{\hat{b}_i} = x_n^c + \frac{(x_n^c - x_n^{b_i}) * \rho(c, \hat{b}_i)}{\rho(c, b_i)} \end{cases}, \quad (1)$$

где  $\rho(C, b_i)$  – евклидово расстояние от центральной точки  $C$  класса до точки  $b_i$ ;  $\rho(C, \hat{b}_i)$  – евклидово расстояние от центральной точки  $C$  класса до точки  $\hat{b}_i$ .

Евклидово расстояние от центральной точки  $C$  класса до точки расширенной выпуклой оболочки класса определяют по формуле:

$$\rho(C, \hat{b}_i) = H' \frac{\rho(c, b_i)}{H}, \quad (2)$$

где  $H$  – сумма евклидовых расстояний от центральной точки  $C$  класса до соответствующих точек выпуклой границы,  $H'$  – сумма евклидовых расстояний от центральной точки  $C$  класса до  $t$  соответствующих точек расширенной выпуклой границы, определяемая плотностью распределения объектов класса в секторе.

Сумму евклидовых расстояний  $H$  от центральной точки  $C$  класса до точки  $b_i$  и соседней точки  $b_{i-1}$  определяют по формуле:

$$H = \rho(C, b_i) + \rho(C, b_{i-1}), \quad (3)$$

где  $\rho(C, b_i)$  – евклидово расстояние от центральной точки  $C$  до точки  $b_i$ ;  $\rho(C, b_{i-1})$  – евклидово расстояние от центральной точки  $C$  до точки  $b_{i-1}$ .

Сумму евклидовых расстояний  $H'$  от центральной точки  $C$  класса до точки  $\hat{b}_i$  и соседней точки  $\hat{b}_{i-1}$ , определяемую плотностью распределения объектов класса в секторе, вычисляют по формуле:

$$H' = H + \left( \frac{H}{\sum_{z=1}^{S^k} h_z / H * 1 / S^k} - H \right) * \frac{S^k}{T/k}, \quad (4)$$

где  $S^k$  – количество точек в текущем секторе класса;  $k$  – количество секторов в классе;  $T$  – общее количество точек в классе;  $h_z$  – сумма евклидовых расстояний от точки внутри сектора  $t_f, f = \overline{1, S^k}$  до точки  $b_i$  и точки  $b_{i-1}$ .

Сумму евклидовых расстояний  $h_z$  от точки внутри сектора  $t_f$  до точки  $b_i$  и точки  $b_{i-1}$  определяют по формуле:

$$h_z = \rho(t_f, b_i) + \rho(t_f, b_{i-1}). \quad (5)$$

Для каждой точки расширенной выпуклой оболочки класса, входящей одновременно в два соседних сектора, вычисляют и усредняют между собой, соответственно, два комплекта координат, определяют расширенную выпуклую оболочку класса, соединяя точки  $\hat{b}_i$ .

4. Далее в каждом секторе в выпуклую оболочку класса добавляют точки  $a_j$ , которые находятся на минимальном расстоянии от двух соседних точек выпуклой оболочки, причем, их добавление в оболочку производят при условии, что другие точки не окажутся вне оболочки класса, при этом  $a_j = (x_1^a, x_2^a, \dots, x_n^a), j = \overline{1, G}$ , где  $(x_1^a, x_2^a, \dots, x_n^a)$  – координаты точки в  $n$ -мерном пространстве признаков;  $G$  – количество добавленных точек.

Формируют вогнутую по форме и минимальную по площади оболочку класса, соединяя точки  $b_i$  и точки  $a_j$ , затем добавленные в выпуклую оболочку класса точки  $a_j$  преобразуют в точки  $\hat{a}_j = (x_1^{\hat{a}_j}, x_2^{\hat{a}_j}, \dots, x_n^{\hat{a}_j}), j = \overline{1, G}$ , где  $(x_1^{\hat{a}_j}, x_2^{\hat{a}_j}, \dots, x_n^{\hat{a}_j})$  – координаты точки в  $n$ -мерном пространстве признаков;  $G$  – количество добавленных точек  $\hat{a}_j$ , по формуле:

$$\begin{cases} x_1^{\hat{a}_j} = x_1^{b_i} - \frac{\rho(\hat{b}_i, \hat{b}_{i-1})}{\rho(b_i, b_{i-1})} * (x_1^{b_i} - x_1^{a_j}) \\ x_2^{\hat{a}_j} = x_2^{b_i} - \frac{\rho(\hat{b}_i, \hat{b}_{i-1})}{\rho(b_i, b_{i-1})} * (x_2^{b_i} - x_2^{a_j}), \\ \dots \\ x_n^{\hat{a}_j} = x_n^{b_i} - \frac{\rho(\hat{b}_i, \hat{b}_{i-1})}{\rho(b_i, b_{i-1})} * (x_n^{b_i} - x_n^{a_j}) \end{cases} \quad (6)$$

где  $\rho(b_i, b_{i-1})$  – евклидово расстояние между соседними точками выпуклой оболочки  $b_i$  и  $b_{i-1}$ ;  $\rho(\hat{b}_i, \hat{b}_{i-1})$  – евклидово расстояние между соседними точками расширенной выпуклой оболочки.

5. Далее формируют окончательную оболочку класса, соединяя точки  $\hat{b}_i$  и точки  $\hat{a}_j$ . Добавление в итоговую границу точек позволяет учитывать форму распределения объектов класса в евклидовом пространстве.

Классификатор считают обученным и готовым к использованию, когда на основании математической модели и разработанного метода построены границы каждого класса.

Для использования классификатора исследуемый объект помещают в  $n$ -мерное пространство признаков. Координатами исследуемого объекта являются его характеристики. Далее осуществляют проверку попадания исследуемого объекта по его координатам в  $n$ -мерном пространстве

признаков в каждую из областей, определяемых границами  $N$  предварительно заданных классов.

Такой подход к задаче классификации позволяет не только распределить объекты на классы, но и повысить точность работы системы, указав на объекты, не относящиеся ни к одному из интересующих классов.

### Литература

1. Rifkin R., Aldebaro K. 2004. In Defense of One-Vs-All Classification. *Journal of Machine Learning Research*. №vol, 5: 101–141. URL: [jmlr.org/papers/volume5/rifkin04a/rifkin04a.pdf](http://jmlr.org/papers/volume5/rifkin04a/rifkin04a.pdf).
  2. Комарцова Л. Г., Максимов А. В. *Нейрокомпьютеры: Учебное пособие для вузов*. М.: Изд-во МГТУ им. Н.Э. Баумана, 2002. - 320 с.
  3. Круглов В. В., Борисов В. В. *Искусственные нейронные сети. Теория и практика*. М.: Горячая линия-Телеком, 2001. – С. 382.
  4. Гонсалес Р., Вудс Р. *«Цифровая обработка изображений»*. М.: Техносфера, 2005. – 1072 с.
  5. Ясницкий Л.Н. *Введение в искусственный интеллект: Учебное пособие для студ. высш. учебн. заведений*. М.: Издательство «Академия», 2005. 176 с.
  6. Shapiro M.J., Bonhab G.M. Cognitive processes and foreign policy decision-making. *International Studies Quarterly*. 1973. №17. pp.147-174.
  7. Коротеев М.В. Обзор некоторых современных тенденций в технологии машинного обучения. // *E-Management*. 2018. №1. С. 26-35. URL: [doi.org/10.26425/2658-3445-2018-1-26-35](https://doi.org/10.26425/2658-3445-2018-1-26-35).
  8. Гданский Н.И., Рысин М.Л., Крашенинников А.М. Линейная классификация объектов с использованием нормальных гиперплоскостей. // *Инженерный вестник Дона*, 2012, № 4. URL: [ivdon.ru/magazine/archive/n4ply2012/1324/](http://ivdon.ru/magazine/archive/n4ply2012/1324/).
-



9. Гданский Н.И., Крашенников А.М. Бинарная кластеризация объектов в многомерных пространствах признаков // Труды Социологического конгресса. РГСУ, 2012. С. 94-989.
10. Крашнин А.М., Гданский Н.И. Рысин М.Л. Построение сложных классификаторов для объектов в многомерных пространствах. // Инженерный вестник Дона, 2013, № 2. URL: [ivdon.ru/magazine/archive/n2ply2013/1611/](http://ivdon.ru/magazine/archive/n2ply2013/1611/)

### References

1. . Rifkin R., Aldebaro K. Journal of Machine Learning Research. 2004. №5. pp. 101–141. URL: [jmlr.org/papers/volume5/rifkin04a/rifkin04a.pdf](http://jmlr.org/papers/volume5/rifkin04a/rifkin04a.pdf)
  2. Komartsova L.G., Maksimov A.V. Neyrokompyutery: Uchebnoye posobie dlya vuzov [Neurocomputers: A textbook for universities]. Moskva, Izdatel'stvo MGTU N.E. Baumana, 2002. p. 320.
  3. Kruglov V.V., Borisov V.V. Iskusstvennyye neyronnyye seti. Teoriya i praktika [Artificial neural networks. Theory and practice]. Moskva, Goryachaya liniya-Telekom, 2001. p. 382.
  4. Gonzalez R., Woods R. Tsifrovaya obrabotka izobrazhenii [Digital image processing]. M.: Tecnosfera, 2005. p. 1072.
  5. Yasnitsky L.N. Vvedenie v iskusstvennyy intellekt: Uchebnoye posobie dlya studentiov vysshikh uchebnykh zavedeniy [Introduction to Artificial Intelligence: A textbook for students of higher educational institutions]. Moskva, Izdatel'stvo "Akademiya", 2005. p. 176.
  6. Shapiro M.J., Bonhab G.M. International Studies Quarterly. 1973. №17. p.147-174.
  7. Koroteev M.V. E-Management. 2018. №1. pp. 26-35. URL: [doi.org/10.26425/2658-3445-2018-1-26-35](https://doi.org/10.26425/2658-3445-2018-1-26-35)
-



8. Gdansky N.I., Rysin M.L., Krashennikov A.M. Inzhenerny vestnik Dona, 2012, № 4. URL: [ivdon.ru/magazine/archive/n4ply2012/1324/](http://ivdon.ru/magazine/archive/n4ply2012/1324/).
9. Gdansky N.I., Krashennikov A.M. Trudy Sotsiologicheskogo kongressa. RSGU, 2012. pp. 94-98.
10. Krashennikov A.M., Gdansky N.I., Rysin M.L. Inzhenerny vestnik Dona, 2013, № 2. URL: [ivdon.ru/magazine/archive/n2ply2013/1611/](http://ivdon.ru/magazine/archive/n2ply2013/1611/).