

УДК 519.6

Е. Д. Агафонов, Е. С. Мангалова

ОБ ОДНОМ АЛГОРИТМЕ КЛАССИФИКАЦИИ С ИСПОЛЬЗОВАНИЕМ КОЛЛЕКТИВОВ НЕПАРАМЕТРИЧЕСКИХ МОДЕЛЕЙ

Обсуждается проблема построения непараметрического классификатора. Рассматривается подход к построению модели решающего правила в случае большой размерности вектора признаков и больших объемов выборки. Предлагается алгоритм коллективной оценки k ближайших соседей, позволяющий существенно сократить число требуемых вычислительных операций. Работа алгоритма демонстрируется на прикладной задаче.

Ключевые слова: классификация, коллективы решающих правил, оценка k ближайших соседей.

В современных теории и практике компьютерного анализа данных классификация занимает важное место. В настоящее время существует множество подходов к решению задачи классификации в случае, когда исследователю доступна случайная выборка измерений классифицируемых признаков с указаниями учителя [1; 2]. Многие из этих подходов основаны на использовании байесовой процедуры принятия решения, когда решающее правило можно формировать в классе непараметрических регрессионных моделей. Однако высокая вычислительная сложность при реализации соответствующих алгоритмов затрудняет использование указанного подхода для случаев, когда размерность вектора признаков и объем обучающей выборки достаточно велики. Авторами предложен алгоритм классификации с использованием метода k ближайших соседей, предполагающий декомпозицию задачи с использованием коллективов решающих правил и упорядочиванием выборки.

Рассмотрим алгоритм построения непараметрического классификатора на примере двувальтернативной задачи распознавания образов.

Пусть $(x_i, y_i), i = \overline{1, n}$ – обучающая выборка, где $x_i = (x_i^d, d = \overline{1, D}), i = \overline{1, n}$ – значения признаков классифицируемых объектов (среди признаков есть как непрерывные, так и дискретные); y_i – указания учителя об их принадлежности к одному из двух классов:

$$y_i = \begin{cases} 1, & x_i \in \Omega_1, \\ -1, & x_i \in \Omega_2; \end{cases}$$

$(\tilde{x}_i, \tilde{y}_i), i = \overline{1, m}$ – экзаменующая выборка. Условные плотности вероятности распределения значений признаков x для обоих классов неизвестны.

Решающее правило имеет вид

$$\begin{cases} \tilde{x}_i \in \Omega_1, & f(\tilde{x}_i) \geq C, \\ \tilde{x}_i \in \Omega_2, & f(\tilde{x}_i) < C, \end{cases}$$

где C – порог отсечения, $C \in [-1, 1]$; $f(x)$ – решающая функция, $f(x) \in [-1, 1]$. В качестве оценки решающей функции $\hat{f}(x)$ будем использовать непараметрическую статистику [3]:

$$\hat{f}(x) = \frac{\sum_{i=1}^n y_i \prod_{d=1}^D \Phi\left(\frac{x^d - x_i^d}{c_n^d}\right)}{\sum_{i=1}^n \prod_{d=1}^D \Phi\left(\frac{x^d - x_i^d}{c_n^d}\right)}, \tag{1}$$

где Φ – ядерная функция; c_n – параметры размытости, удовлетворяющие следующим свойствам: $c_n > 0; \lim_{n \rightarrow \infty} c_n = 0; \lim_{n \rightarrow \infty} n(c_n)^D = \infty$.

Введем следующие обозначения:

- $TP(C)$ – верно классифицированные положительные примеры, принадлежащие первому классу;
- $TN(C)$ – верно классифицированные отрицательные примеры, принадлежащие второму классу;
- $FN(C)$ – положительные примеры, классифицированные как отрицательные (ошибка I рода);
- $FP(C)$ – отрицательные примеры, классифицированные как положительные (ошибка II рода);
- $TPR(C)$ – доля истинно положительных примеров:

$$TPR(C) = \frac{TP(C)}{TP(C) + FN(C)};$$

- $FPR(C)$ – доля ложно положительных примеров:

$$FPR(C) = \frac{FP(C)}{TN(C) + FP(C)}.$$

Зависимость $TPR(C)$ от $FPR(C)$ образуют кривую ROC (рис. 1).




Рис. 1. Кривая ROC

Оптимизация по параметрам размытости c_n происходит в режиме holdout [4] из условия максимума AUC – площади под кривой ROC [5].

Построение решающей функции (1) для неусеченного ядра Φ во всех точках экзаменуемой выборки потребует $O(nm)$ вычислительных операций. При использовании усеченных ядер время вычисления сокращается, так как локальное усреднение производится только в окрестности каждой точки экзаменуемой выборки.

Однако если учесть, что для оптимизации параметров размытости c_n необходимо повторять процедуру оценивания решающей функции (1) несколько раз, то применение этой функции для выборок большого объема потребует значительного количества вычислительных ресурсов [6]. Сократить количество вычислительных операций для построения оценки регрессии возможно за счет применения линейных непараметрических коллективов решающих правил, смысл которых состоит в декомпозиции исходной задачи, построении семейства локальных решающих функций и последующей их организации в едином линейном решающем правиле [1].

Для построения локальных (частных) решающих функций предлагается формировать наборы признаков $x(j), j = \overline{1, N}$ из исходных $x = (x^1, x^2, \dots, x^D)$, причем каждый набор признаков $x(j)$ должен содержать только один непрерывный признак и произвольное число дискретных. Семейство частных решающих функций $\hat{f}_j(x(j)) (j = \overline{1, N})$ строится на основании обучающих выборок $V_j = (x_i(j), y_i, i = \overline{1, n}), j = \overline{1, N}$. Процедуру построения частной модели можно условно разбить на два этапа: упорядочивание выборки V_j и оценку k ближайших соседей.

Зададим процедуру упорядочивания выборки. Пусть сформирован набор признаков $x(j) = (x^1, x^2, \dots, x^l)$, где x^1, x^2, \dots, x^{l-1} – дискретные признаки; x^l – непрерывный признак, $l < D$. На первом шаге производится упорядочивание выборки V_j по x^1 , далее – упорядочивание подвыборок с одинаковыми значениями признаков x^1 по x^2 и так до непрерывного признака x^l включительно.

К упорядоченному массиву наблюдений можно применить оценку k ближайших соседей:

$$\hat{f}_j(\tilde{x}^l) = \frac{\sum_{\substack{i=v-k \\ i \neq v}}^{v+k} \Phi\left(\frac{x_i^l - \tilde{x}^l}{c_n^x}\right) y_i}{\sum_{\substack{i=v-k \\ i \neq v}}^{v+k} \Phi\left(\frac{x_i^l - \tilde{x}^l}{c_n^x}\right)}, \quad (2)$$

где v – индекс точки экзаменуемой выборки в упорядоченной выборке V_j ; c_n^x – максимальное расстояние от \tilde{x}^l до x_i^l такое, что $|i-v| \leq k$. Таким образом, независимо от числа признаков, включенных в частную

модель, оптимизация критерия AUC производится по одному параметру – числу ближайших соседей k .

Предлагаемый алгоритм работает следующим образом (рис. 2). Для построения оценки в точке i_1 достаточно ближайших соседей, для которых значения признака x^{l-1} равны 1. Объем подвыборки, значения признака x^{l-1} элементов которой равны 3, меньше $2k$, и при построении оценки в точке i_2 происходит включение в оценку элементов соседней подвыборки.




Рис. 2. Работа алгоритма коллективной оценки k ближайших соседей для упорядоченной выборки

Для построения одной частной решающей функции во всех точках экзаменуемой выборки требуется $O(km)$ вычислительных операций.

Интеграция частных решающих функций $\hat{f}_j(x(j)) (j = \overline{1, N})$ в линейном коллективе решающих правил $\hat{f}(\bar{x})$ [1] осуществляется в соответствии с процедурой

$$\hat{f}(\bar{x}) = \sum_{j=1}^N w_j \hat{f}_j(x(j)),$$

где $w_j (j = \overline{1, N})$ – положительные веса, для которых справедливо равенство

$$\sum_{j=1}^N w_j = 1.$$

В силу того что веса w_j оптимизируются после построения частных решающих функций $\hat{f}_j(x(j)) (j = \overline{1, N})$, перестроения моделей с целью оптимизации не требуется.

Таким образом, сокращение количества вычислительных операций достигается как за счет сокращения количества одновременно настраиваемых параметров, так и за счет экономии вычислительных ресурсов при построении решающих функций.

Численные исследования алгоритма проводились на данных Give Me Some Credit [7], содержащих информацию о кредитной истории 150 000 клиентов банка. Требовалось синтезировать решающее правило, позволяющее отнести клиента к одному из двух классов: заемщикам с наличием или отсутствием

выплат, просроченных на срок более 90 дней за 2 следующих года.

Непрерывные признаки: x^1 – общий баланс по кредитным картам, деленный на сумму кредитного лимита; x^2 – возраст заемщика; x^3 – ежемесячные выплаты долгов, алиментов, расходы на проживание, деленные на ежемесячный доход; x^4 – ежемесячный доход.

Дискретные признаки: x^5 – количество просроченных выплат на срок от 30 до 59 дней за 2 предыдущих года (7 различных значений для 99,756 % наблюдений, 0,179 % наблюдений – пропуски данных); x^6 – количество открытых кредитов (кредиты на покупку автомобиля и ипотека) и кредитных карт (27 значений для 99,4 % наблюдений); x^7 – количество просроченных выплат на срок более 90 дней за 2 предыдущих года (7 значений для 99,752 % наблюдений, 0,179 % наблюдений – пропуски данных); x^8 – количество ипотечных займов (8 значений для 99,799 % наблюдений); x^9 – количество просроченных выплат на срок от 60 до 89 дней за 2 предыдущих года; x^{10} – число иждивенцев (8 значений для 97,36 % наблюдений, 2,616 % наблюдений – пропуски данных).

По признакам $x^5, x^6, x^7, x^8, x^9, x^{10}$ можно производить последовательные сортировки, а по переменным x^1, x^2, x^3, x^4 – вычислять оценку k ближайших соседей. В качестве ядерной функции выбрано треугольное ядро [6].

Наборы признаков формировались последовательным добавлением дискретных признаков $x^5, x^6, x^7, x^8, x^9, x^{10}$ к непрерывным признакам x^1, x^2, x^3, x^4 . Значения AUC для частных решающих функций (2), построенных по выборкам V_j со всевозможными наборами из одного и двух признаков, приведены в табл. 1, с наборами из двух и трех признаков – в табл. 2.

Учет признака x^6 при построении частной решающей функции по непрерывному признаку x^1 и признаку x^{10} при построении частной решающей функции по непрерывному признаку x^2 привел к уменьшению критерия качества (см. значения, выделенные курсивом в табл. 1).

В результате была получена убывающая по AUC последовательность наборов признаков. Наибольшем значению AUC соответствует набор признаков (x^7, x^9, x^5, x^8, x^1), $AUC = 0,8519$.

Таблица 1

Значения AUC для частных моделей, построенных с использованием одного или двух признаков

x^1	0,782 8	0,819 7	0,779 0	0,818 1	0,785 2	0,810 2	0,786 5
x^2	0,633 2	0,754 0	0,652 4	0,733 5	0,651 1	0,713 1	0,632 9
x^3	0,578 6	0,723 0	0,638 7	0,715 1	0,641 6	0,677 4	0,587 1
x^4	0,580 4	0,723 1	0,605 8	0,695 4	0,605 4	0,672 0	0,595 1
Признак	–	x^5	x^6	x^7	x^8	x^9	x^{10}

Таблица 2

Значения AUC для частных моделей, построенных с использованием двух или трех признаков

x^1	0,819 7	0,816 5	0,841 6	0,827 2	0,836 9	0,821 4
x^2	0,754 0	0,769 7	0,798 3	0,761 3	0,779 7	0,753 0
x^3	0,723 0	0,759 6	0,786 1	0,752 5	0,760 6	0,726 6
x^4	0,723 1	0,747 7	0,774 4	0,739 6	0,755 8	0,730 3
Признак	x^5	$x^5 x^6$	$x^5 x^7$	$x^5 x^8$	$x^5 x^9$	$x^5 x^{10}$
x^1	0,816 6	0,779 0	0,817 3	0,784 5	0,809 6	0,775 4
x^2	0,764 7	0,652 4	0,737 3	0,656 7	0,719 4	0,646 8
x^3	0,751 8	0,638 7	0,725 8	0,660 7	0,707 1	0,632 6
x^4	0,741 5	0,605 8	0,705 2	0,610 8	0,688 6	0,615 3
Признак	$x^6 x^5$	x^6	$x^6 x^7$	$x^6 x^8$	$x^6 x^9$	$x^6 x^{10}$
x^1	0,842 1	0,820 1	0,818 1	0,822 2	0,834 6	0,816 9
x^2	0,797 1	0,744 5	0,733 5	0,741 8	0,766 5	0,733 4
x^3	0,784 1	0,736 6	0,715 1	0,745 7	0,752 8	0,718 4
x^4	0,777 0	0,713 5	0,695 4	0,7144	0,7377	0,705 6
Признак	$x^7 x^5$	$x^7 x^6$	x^7	$x^7 x^8$	$x^7 x^9$	$x^7 x^{10}$
x^1	0,821 3	0,775 2	0,823 2	0,785 2	0,815 6	0,788 2
x^2	0,759 8	0,657 9	0,740 5	0,651 1	0,723 3	0,651 9
x^3	0,750 3	0,662 4	0,743 1	0,641 6	0,716 9	0,647 6
x^4	0,738 5	0,611 2	0,711 4	0,605 4	0,690 2	0,617 1
Признак	$x^8 x^5$	$x^8 x^6$	$x^8 x^7$	x^8	$x^8 x^9$	$x^8 x^{10}$

x^1	0,832 2	0,807 3	0,831 7	0,813 3	0,810 2	0,808 0
x^2	0,779 8	0,727 9	0,766 4	0,724 3	0,713 1	0,712 6
x^3	0,760 9	0,716 6	0,753 7	0,719 4	0,677 4	0,680 7
x^4	0,756 0	0,694 4	0,732 4	0,694 2	0,672 0	0,684 6
Признак	$x^9 x^5$	$x^9 x^6$	$x^9 x^7$	$x^9 x^8$	x^9	$x^9 x^{10}$
x^1	0,816 2	0,770 0	0,815 5	0,780 4	0,806 6	0,786 5
x^2	0,751 8	0,646 8	0,731 6	0,651 0	0,711 9	0,632 9
x^3	0,725 6	0,631 0	0,713 9	0,646 8	0,680 6	0,585 7
x^4	0,728 5	0,615 3	0,703 4	0,617 0	0,682 5	0,585 1
Признак	$x^{10} x^5$	$x^{10} x^6$	$x^{10} x^7$	$x^{10} x^8$	$x^{10} x^9$	x^{10}

На основе анализа результатов построения частных моделей с различными наборами признаков были сделаны выводы о степени влияния каждого признака на отклик относительно других, т. е. было проведено ранжирование непрерывных и дискретных признаков:

$$x^1 > x^2 > x^3 > x^4,$$

$$x^5 \approx x^7 \approx x^9 > x^8 > x^6 > x^{10},$$

где $a > b$ означает, что влияние признака a выше влияния признака b ; $a \approx b$ – однозначное сравнение влияния не может быть произведено.

Объединение частных моделей в линейный коллектив позволяет повысить качество модели: при объединении 5 частных моделей $AUC = 0,861$ 1, при объединении 13 частных моделей $AUC = 0,864$ 1, дальнейшее же увеличение коллектива к существенному увеличению AUC не приводит. Объединение проводилось последовательным добавлением случайно выбранной частной модели к коллективу. В случае отсутствия улучшения качества модели добавленная частная модель удалялась. За первоначальный коллектив была взята частная модель, построенная по набору признаков (x^7, x^9, x^5, x^8, x^1) и оптимальная в смысле AUC . Для решения задачи выбора оптимального набора признаков потребовалось построить 42 частные модели: 4 – для выбора непрерывного признака, 6 – для выбора первого дискретного признака, 5 – для выбора второго дискретного признака, 4 – для выбора третьего дискретного признака, 3 – для выбора четвертого дискретного признака и $24 = 4!$ для определения порядка дискретных признаков.

Предлагаемый алгоритм сравнивался с алгоритмами, вычислительные затраты которых также линейно зависят от объема выборки и количества элементов в коллективе:

- бинарное дерево регрессии [2] (89 вершин) – $AUC = 0,852$ 4;
- алгоритм Random Forest [8] (500 деревьев) – $AUC = 0,864$ 2.

При равных показателях критерия AUC предлагаемый алгоритм требует меньшее количество вычислительных ресурсов.

Библиографические ссылки

1. Лапко А. В., Лапко В. А. Непараметрические системы обработки неоднородной информации. Новосибирск : Наука, 2007.
2. Classification and Regression Trees / L. Breiman, J. H. Friedman, R. A. Olshen, C. J. Stone. Monterey, Calif. : Wadsworth & Brooks/Cole Advanced Books & Software, 1984.
3. Nadaraya E. A. Nonparametric Estimation of Probability Densities and Regression Curves. Mathematics and its Applications. Dordrecht : Kluwer Academic Publishers Group, 1989/ (Sov. Ser. 20).
4. Kohavi R. A. Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection // Proc. of Intern. Joint Conf. on Artificial Intelligence. Montreal, Quebec, 1995. P. 1137–1145.
5. Fawcett T. ROC Graphs: Notes and Practical Considerations for Researchers. Dordrecht : Kluwer Academic Publ., 2004.
6. Хардле В. Прикладная непараметрическая регрессия. М. : Мир, 1993.
7. Data Mining Competition: Give Me Some Credit [Electronic resource]. URL: www.kaggle.com/c/Give-Me-Some-Credit (date of visit: 1.04.2012).
8. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45, № 1. P. 5–32.

E. D. Agafonov, E. S. Mangalova

A CLASSIFICATION ALGORITHM BASED ON ENSEMBLES OF NONPARAMETRIC MODELS

The paper deals with a classification strategy which utilises nonparametric modeling of a decision rule in a case of large feature vector length and large sample volume. An algorithm of collective assessment of k-nearest neighbors is proposed, which significantly reduces the computational cost. The work of algorithm is demonstrated on one application problem.

Keywords: classification, ensemble of decision rules, k-nearest neighbors.