

Вероятностный выход для методов многоклассовой классификации на основе самокорректирующихся кодов

Соболев А. А., Вежневцев А. П., Вежневцев В. П.

neusobol@yandex.ru, {avezhnevets,dmoroz}@graphics.cs.msu.ru

Москва, МГУ им. М. В. Ломоносова,

Лаборатория машинной графики и мультимедиа

Одним из способов сведения задачи классификации с множеством классов к задаче бинарной классификации (с двумя классами) является семейство методов, основанных на самокорректирующихся кодах [1]. В этой статье рассматривается получение вероятностного выхода для данного семейства методов.

Введение

Пусть дана обучающая выборка $D = \{(x_n, y_n)\}_{n=1}^N \subset X \times Y$, где X — множество образов, а $Y = \{c_1, \dots, c_n\}$ — множество меток классов. Пусть $M \in \{\pm 1\}^{C \times T}$ — кодовая матрица, где T — длина кодового слова. Финальный классификатор представляет собой комитет $f(x) = [f_1(x), \dots, f_T(x)]^T$, где $f_t: X \rightarrow \mathbb{R}$. В итоге настроенный классификатор работает по принципу минимального расстояния, то есть классом нового объекта x считается тот класс y^* , расстояние до кодового слова $M(y^*)$ которого минимально $y^* = \arg \min_y \Delta(M(y), f(x))$. Обычно используется следующая формула расстояния: $\Delta(M(y), f(x)) = \sum_{t=1}^T \alpha_t \frac{1 - M(k,t)f_t(x)}{2}$.

Классический подход к получению вероятностей

Использование самокорректирующихся кодов дает существенный прирост в качестве классификации. Однако, для многих прикладных задач, например задач машинного зрения, требуется получение не просто наиболее вероятного класса для прецедента, но и вероятности принадлежности прецедента к тому или иному классу. Ранее для решения данной задачи предлагалось использовать подход, основанный на сведении задачи к решению системы линейных уравнений [2]. Пусть для каждого классификатора из комитета $f_t(x)$ можно вычислить вероятностный выход $P(f_t(x))$. Пусть $p = \langle P(f_1(x)), \dots, P(f_T(x)) \rangle$. Например, если столбец t кодовой матрицы M равен $\langle 1, 0, 1 \rangle$, то $P(f_t(x)) = P(c_1|x) + P(c_3|x)$. Обозначим $z = \langle P(c_1|x), \dots, P(c_k|x) \rangle$ — вектор искомых вероятностей. Тогда можно записать матричное уравнение $M^T z = p$. Решая эту систему, мы получим искомые вероятности. Система, вообще говоря, может быть несовместной, поэтому предлагается использовать метод наименьших квадратов. Данный метод имеет ряд недостатков:

- для каждого классифицируемого прецедента приходится решать систему заново, из-за чего метод становится вычислительно сложным;
- метод вычислительно неустойчив — зависит от обусловленности матрицы M .

Предлагаемый метод

Предлагается использовать подход, основанный на нормировке отступа, аналогично [3, 4]. Для этого требуется определить отступ для каждого конкретного класса и выбрать метод шкалирования значения отступа для аппроксимации условной вероятности класса. Отступ для класса c_i определим как

$$\rho(c_i, f(x)) = \min_{c \in Y, c \neq c_i} \Delta(M(c), f(x)) - \Delta(M(c_i), f(x)).$$

Для того, чтобы отступ максимально точно аппроксимировал апостериорную вероятность, применим алгоритм шкалирования [3, 4], в котором предлагается преобразовать отступ сигмоидальной функцией с параметрами, минимизирующими невязку предсказанной вероятности и реальной. Заметим, что при вычислении ответа на образ x вычисление отступов и вероятностей почти не требует дополнительных вычислений — расстояния до кодовых слов будут рассчитаны в любом случае во время классификации:

$$P(c_i|x) \approx \frac{1}{1 + \exp(A\rho(c_i, f(x)) + B)}.$$

Оценка параметров сигмоиды A и B производится на отдельной проверочной выборке, не являющейся ни частью обучающей, ни частью контрольной. В качестве альтернативы можно использовать скользящий контроль с глубиной 3, как предложено в [3].

Эксперименты

Мы сравнили работу своего метода и классического на нескольких выборках из репозитория задач UCI [5]. Мы использовали скользящий контроль глубины 3 для настройки параметров сигмоиды (для каждого класса отдельно). В качестве бинарных классификаторов мы использовали комитет деревьев глубины один (stumps), построенный методом AdaBoost.

Ниже приводятся диаграммы калибровки [4] для различных классов из набора `abalone` для классического и предложенного метода (из-за ограниченного места мы, к сожалению, не можем привести больше графиков). Диаграммы строятся следующим образом. Весь диапазон предсказанных

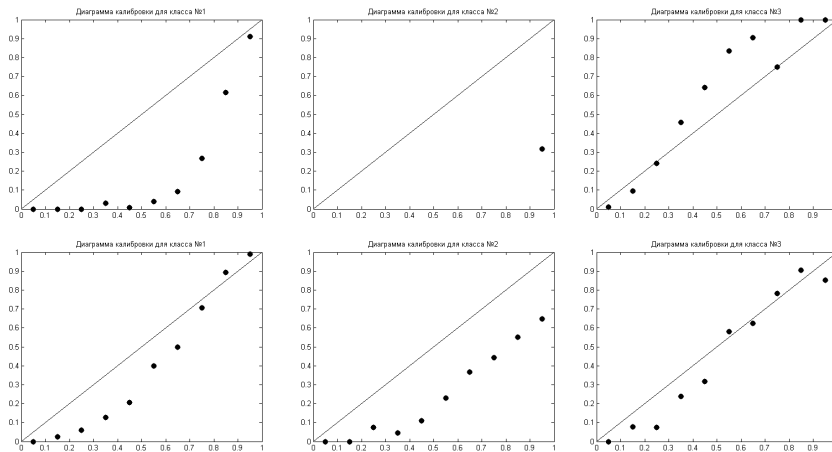


Рис. 1. Результаты экспериментов. Три верхних графика получены методом [2], нижние с помощью предложенного метода.

вероятностей делится на ячейки. Для каждой ячейки считается реальная доля прецедентов исследуемого класса. Чем ближе точки лежат к диагональной прямой, тем лучше откалиброван метод. Как видно из графиков, предложенный метод дает более адекватные результаты. Еще раз отметим, что предложенный метод вычислительно намного проще.

Литература

- [1] *Dietterich T., Bakiri G.* Solving Multiclass Learning Problems via Error-Correcting Output Codes. // *Journal of Artificial Intelligence Research.* — 1995. — Pp. 263–286.
- [2] *Kong E., Diettrich T.* Probability estimation via error-correcting output coding. // *Int'l. Conf. of Artificial Intelligence and soft computing.* — 1997.
- [3] *Platt J.* Probabilistic outputs for support vector machines and comparison to regularized likelihood methods. // *Advances in Large Margin Classifiers.* — 1999. — Pp. 61–74.
- [4] *Niculescu-Mizil A. and Caruana R.* Predicting good probabilities with supervised learning. // *22nd int'l conf. on Machine learning.* — 2005. — Pp. 625–632.
- [5] *Asuncion A., Newman D. J.* UCI Machine Learning Repository // University of California, Irvine. — 2007. — www.ics.uci.edu/~mllearn/MLRepository.html