

## Обучение композиций дипольных классификаторов на основе EM-алгоритма

*Пустовойтов Н. Ю.*

pustovoytov@forecsys.ru

Москва, МФТИ, ЗАО «Форексис»

Идея дипольного классификатора, предложенная в [2], так же, как и идея метода потенциальных функций [1], заимствована из физики. Диполем называется пара зарядов, имеющих одинаковый по модулю, но противоположный по знаку заряд, и расположенных на незначительном расстоянии друг от друга. Диполь разделяет пространство плоскостью на области положительного и отрицательного потенциала. Поэтому его можно рассматривать как линейный классификатор, заданный двумя точками (полюсами диполя), либо как алгоритм ближайшего соседа, построенный по выборке из двух объектов (полюсов). В данной работе рассматриваются композиции дипольных классификаторов.

### Дипольный классификатор

Пусть  $X \subset \mathbb{R}^n$  — множество объектов,  $Y = \{-1, +1\}$  — множество меток классов. Требуется построить алгоритм классификации  $a: X \rightarrow Y$ , восстанавливающий неизвестную целевую зависимость  $y^*: X \rightarrow Y$  по обучающей выборке  $X^\ell = \{x_1, \dots, x_\ell\}$ ,  $y_i = y^*(x_i)$ . Предполагается, что на множестве объектов определена функция расстояния  $\rho(x, x')$ .

Пусть  $K: \mathbb{R}_+ \rightarrow \mathbb{R}_+$  — заданная невозрастающая функция.

Дипольным классификатором (или просто диполем) с ядром  $K$ , полюсами  $r^-$ ,  $r^+$  и радиусом  $d$  назовём функцию  $a: X \rightarrow Y$  вида

$$a(x) = \text{sign} \left( K \left( \frac{\rho(x, r^+)}{d} \right) - K \left( \frac{\rho(x, r^-)}{d} \right) \right). \quad (1)$$

Диполь совпадает с байесовским классификатором, если предположить, что плотности классов имеют вид  $p(x|y) = p(x; r^y, d) = \frac{1}{K_0} K \left( \frac{\rho(x, r^y)}{d} \right)$ , где  $K_0$  — нормировочный коэффициент;  $r^-$ ,  $r^+$ ,  $d$  — параметры диполя.

Введём также неотрицательную функцию компетентности диполя  $C(x; r^-, r^+, R)$ , значение которой непрерывно и монотонно убывает по мере удаления от полюсов диполя, а скорость убывания задаётся радиусом функции компетентности  $R$ , вообще говоря, отличным от радиуса диполя  $d$ . Будем рассматривать только такие функции компетентности, которые симметричны относительно полюсов диполя. Существует три

принципиально различных варианта задания таких функций:

$$C(x; r^-, r^+, R) = K' \left( \frac{\rho(x, r^+)}{R} \right) K' \left( \frac{\rho(x, r^-)}{R} \right); \quad (2)$$

$$C(x; r^-, r^+, R) = K' \left( \frac{\rho(x, r^+) + \rho(x, r^-)}{2R} \right); \quad (3)$$

$$C(x; r^-, r^+, R) = K' \left( \frac{1}{R} \rho \left( x, \frac{r^+ + r^-}{2} \right) \right); \quad (4)$$

где  $K': \mathbb{R}_+ \rightarrow \mathbb{R}_+$  — заданная невозрастающая функция, вообще говоря, отличная от ядра  $K$ . Три варианта соответствуют трём способам агрегирования расстояний до полюсов: на уровне ядер (2), на уровне функций расстояния (3), и на уровне самих полюсов (4).

### Композиция дипольных классификаторов

Композицией из  $T$  диполей с параметрами  $\Theta = (r_t^-, r_t^+, d_t, R_t, Q_t)_{t=1}^T$ , будем называть алгоритм классификации вида

$$a(x; \Theta) = \text{sign} \left( \sum_{t=1}^T g_t(x, \Theta) \left( p(x; r_t^+, d_t) - p(x; r_t^-, d_t) \right) \right), \quad (5)$$

где  $g_t(x, \Theta)$  — *шлюзовая функция* (gate [3]), оценивающая компетентность  $t$ -го диполя в точке  $x$ . Если шлюзовые функции нормированы,

$$g_t(x; \Theta) = \frac{Q_t C(x; r_t^+, r_t^-, R_t)}{\sum_{s=1}^T Q_s C(x; r_s^+, r_s^-, R_s)},$$

то композицию диполей можно интерпретировать как *смесь экспертов* [3], а сами шлюзовые функции — как априорные вероятности того, что объект  $x$  порождён  $t$ -й компонентой смеси. Возвращаясь к физической аналогии, параметр  $Q_t$  можно интерпретировать как заряд диполя.

### Построение смеси диполей

Композицию диполей удобно настраивать с помощью EM-алгоритма. На каждой EM-итерации сначала вычисляются «скрытые переменные» — апостериорные вероятности  $h_{ti}$  того, что объект  $x_i$  порождён  $t$ -й компонентой смеси (E-шаг). Благодаря скрытым переменным задача максимизации правдоподобия распадается на  $T$  независимых подзадач, по одной для каждого диполя (M-шаг), которые решаются стандартными методами. Возможен вариант, когда полюса диполей выбираются только из обучающих объектов. Если правдоподобие значительной доли объектов оказывается слишком низким, и среди них есть достаточное количество объектов обоих классов, то в композицию вводится новый диполь.

В докладе подробно рассматриваются различные альтернативные варианты построения дипольной композиции, а также вопросы ускорения сходимости. В экспериментах на модельных данных алгоритм показал хорошее качество классификации линейно разделимой выборки и выборки типа XOR, построив один и два диполя соответственно.

#### **Достоинства дипольных композиций**

Благодаря вероятностной модели, наряду с классификацией, могут быть выданы оценки принадлежности объекта каждому из классов, а также выделены *нетипичные объекты*, находящиеся в зоне низкой компетентности всех диполей.

Классификации легко интерпретируются в терминах сходства: «объект  $x$  отнесён к классу  $y$  потому, что он близок к эталонному объекту  $x_i$  класса  $y$ ». Эталонными объектами являются полюса диполей.

В зависимости от целей применения в роли полюсов могут выступать либо обучающие объекты, либо произвольные точки пространства  $X$ .

Благодаря EM-алгоритму с динамическим добавлением компонент строится минимальное необходимое число диполей, в отличие от таких композиционных алгоритмов, как бустинг и бэггинг.

Для хранения алгоритма достаточно запомнить только полюса диполей (и ещё три числа на каждый диполь). В этом дипольная композиция аналогична методу опорных векторов, SVM [5]. Однако, в отличие от SVM, *опорными* являются не пограничные обучающие объекты (которые часто оказываются шумовыми выбросами), а полюса диполей, найденные оптимизационной процедурой. В этом дипольная композиция аналогична методу релевантных векторов, RVM [4]. Однако, в отличие от RVM, здесь не делается никаких априорных предположений о виде вероятностного распределения в пространстве параметров модели.

Работа выполнена при поддержке РФФИ, проекты № 05-01-00877 и № 05-07-90410, а также программы ОМН РАН «Алгебраические и комбинаторные методы математической кибернетики».

#### **Литература**

- [1] Айзерман М. А., Браверман Э. М., Розоноэр Л. И. Метод потенциальных функций в теории обучения машин. — М.: Наука, 1970. — Р. 320.
- [2] Воронцов К. В. О композициях дипольных классификаторов // Интеллектуализация обработки информации. — Симф., 2006. — С. 38–40.
- [3] Jordan M. I., Jacobs R. A. Hierarchical mixtures of experts and the EM algorithm // Neural Computation. — 1994. — no. 6. — Pp. 181–214.
- [4] Tipping M. The relevance vector machine // Advances in Neural Information Processing Systems, San Mateo, CA. — Morgan Kaufmann, 2000.
- [5] Vapnik V. Statistical Learning Theory. — Wiley, New York, 1998.