

Метод опорных признаков в задаче распознавания объектов двух классов

Н. А. Савинов

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

Научный руководитель д.т.н., в.н.с. ВЦ РАН В. В. Моттль

Москва,
2011 г.

План презентации

- Постановка задачи для метода опорных векторов
- Свойства решения для метода опорных векторов
- Проблема переобучения
- Метод опорных признаков
- Способы решения оптимизационной задачи
- Вычислительный эксперимент

Постановка задачи для классического метода опорных векторов

- Задана обучающая выборка (\mathbf{x}_j, y_j) , $j = 1, \dots, N$, где $\mathbf{x}_j \in \mathbb{R}^n$ — признаковые описания объектов, $y_j \in \{-1, 1\}$ — ответы.
- Рассматривается класс линейных решающих правил:

$$y = \text{sign}\left(\sum_{i=1}^n a_i x_i + b\right)$$
- Выбор оптимального правила сводится к настройке параметров \mathbf{a} , b по обучающей выборке на основе критерия:

$$\begin{cases} \frac{1}{2} \mathbf{a}^T \mathbf{a} + c \sum_{j=1}^N \delta_j \rightarrow \min(\mathbf{a}, b, \delta_j), \\ y_j(\mathbf{a}^T \mathbf{x}_j + b) \geq 1 - \delta_j, \quad j = 1, \dots, N, \\ \delta_j \geq 0, \quad j = 1, \dots, N. \end{cases}$$

Двойственная задача

Пусть λ_j , $j = 1, \dots, N$ — двойственные переменные. Тогда двойственная задача имеет вид:

$$\begin{cases} \sum_{j=1}^N \lambda_j - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \rightarrow \max(\lambda_j), \\ 0 \leq \lambda_j \leq c, \quad j = 1, \dots, N, \\ \sum_{j=1}^N y_j \lambda_j = 0. \end{cases}$$

Свойства двойственной задачи оптимизации:

- Квадратичная
- Вогнутая

Данная задача эффективно решается методом Sequential Minimal Optimization за $O(N^2)$ действий (Platt, 2001).

Решение исходной задачи

Решение прямой задачи выражается через решение двойственной с использованием условий Каруша-Куна-Таккера:

- $\mathbf{a} = \sum_{j=1}^N \lambda_j y_j \mathbf{x}_j$

- $b = \text{med}\{y_j - \mathbf{a}^T \mathbf{x}_j, \lambda_j > 0, j = 1, \dots, N\}$

Свойства решения

- Направляющий вектор \mathbf{a} разделяющей гиперплоскости является линейной комбинацией признаков описаний объектов обучения.
- Объекты, для которых $\lambda_j = 0$, не влияют на положение разделяющей гиперплоскости.
- В случае линейной разделимости выборки метод максимизирует ширину разделяющей полосы между классами.

Переобучение в методе опорных векторов

- В случае, когда $n \geq N$ (то есть когда размерность признакового описания велика, а объектов в обучении мало), метод опорных векторов склонен к переобучению.
- Причина: l_2 -регуляризатор $\frac{1}{2} \mathbf{a}^T \mathbf{a}$, введенный для улучшения обобщающей способности, не отбирает признаки.

Предлагается: l_2 - l_1 регуляризация

- Вводится регуляризатор:

$\sum_{i=1}^n ((1 - \mu)a_i^2 + \mu|a_i|)$, где $\mu \in [0, 1)$ — параметр, позволяющий регулировать селективность метода.

- Получаем критерий обучения:

$$\begin{cases} \sum_{i=1}^n ((1 - \mu)a_i^2 + \mu|a_i|) + c \sum_{j=1}^N \delta_j \rightarrow \min(\mathbf{a}, b, \delta_j), \\ y_j(\mathbf{a}^T \mathbf{x}_j + b) \geq 1 - \delta_j, \quad j = 1, \dots, N, \\ \delta_j \geq 0, \quad j = 1, \dots, N. \end{cases}$$

Двойственная задача

$$\begin{cases} \sum_{j=1}^N \lambda_j - \frac{1}{4(1-\mu)} \sum_{i=1}^n [\min\{\mu + \sum_{j=1}^N y_j \lambda_j x_{ij}, 0, \mu - \sum_{j=1}^N y_j \lambda_j x_{ij}\}]^2 \rightarrow \max(\lambda_j), \\ 0 \leq \lambda_j \leq c, \quad j = 1, \dots, N, \\ \sum_{j=1}^N y_j \lambda_j = 0. \end{cases}$$

Свойства:

- Неквадратичная
- Вогнутая

Решение существует, каждое локальное решение является глобальным.

Решение исходной задачи

Полностью определяется через решение двойственной задачи:

$$a_i = \begin{cases} \frac{\sum_{j=1}^N y_j \lambda_j x_{ij} - \mu}{2(1-\mu)}, & \text{если } \sum_{j=1}^N y_j \lambda_j x_{ij} > \mu, \\ \frac{\sum_{j=1}^N y_j \lambda_j x_{ij} + \mu}{2(1-\mu)}, & \text{если } \sum_{j=1}^N y_j \lambda_j x_{ij} < -\mu, \\ 0, & \text{если } \left| \sum_{j=1}^N y_j \lambda_j x_{ij} \right| \leq \mu, \end{cases}$$

$$b = - \frac{\sum_{0 < \lambda_j < c} \lambda_j \mathbf{a}^T \mathbf{x}_j + c \sum_{\lambda_j = c} y_j}{\sum_{0 < \lambda_j < c} \lambda_j}.$$

Свойства решения

- Некоторые a_i оказываются равными 0, то есть производится отбор признаков.
- Поэтому предложенный метода был назван методом опорных признаков.

Способы решения двойственной задачи

Предлагаются 2 способа:

- Сведение к квадратичной.
- Решение напрямую с помощью обобщения метода Sequential Minimal Optimization на неквадратичный случай.

Квадратичный вид двойственной задачи

$$\left\{ \begin{array}{l} \sum_{j=1}^N \lambda_j - \frac{1}{4(1-\mu)} \sum_{i=1}^n \gamma_i^2 \rightarrow \max(\lambda_j, \gamma_i), \\ \left| \sum_{j=1}^N \lambda_j y_j x_{ij} \right| \leq \gamma_i + \mu, i = 1, \dots, N, \\ 0 \leq \lambda_j \leq c, j = 1, \dots, N, \\ \sum_{j=1}^N y_j \lambda_j = 0. \end{array} \right.$$

- Далее можно использовать стандартные программные пакеты решения задач квадратичного программирования, требующие $O(N^3)$ действий.
- Недостаток: введение дополнительных переменных.

Обобщение метода SMO

- Для использования метода SMO достаточно решить двойственную задачу при 2 свободных переменных λ_{k_1} , λ_{k_2} и фиксированных остальных.
- В силу наличия ограничения-равенства на переменные задача сводится к одномерной максимизации по λ_{k_1} .
- Целевая функция дифференцируема по λ_{k_1} :

$$\frac{dW}{d\lambda_{k_1}} = (1 - y_{k_1}y_{k_2}) - \frac{y_{k_1}}{2(1 - \mu)} (S_1 + S_2) \Big|_{\lambda_{k_2} = \gamma - y_{k_1}y_{k_2}\lambda_{k_1}}, \text{ где}$$

$$S_1 = \sum_{i: \mathbf{x}_{yi}\lambda < -\mu} (\mathbf{x}_{yi}\lambda + \mu)(x_{ik_1} - x_{ik_2}),$$

$$S_2 = - \sum_{i: \mathbf{x}_{yi}\lambda > \mu} (-\mathbf{x}_{yi}\lambda + \mu)(x_{ik_1} - x_{ik_2}),$$

\mathbf{x}_{yi} — вектор-строка матрицы $(y_j x_{ij})$.

Обобщение метода SMO

- Производная представляет собой монотонную кусочно-линейную функцию, состоящую из $(2n + 1)$ участков.
- Для быстрого поиска участка, на котором достигается 0, используется метод дихотомии.
- По найденным концам вычисляются параметры линейного участка, находится точка 0 производной.
- Берется проекция найденной точки безусловного максимума на множество, задаваемое ограничениями-неравенствами. Таким образом, получаем решение задачи условной максимизации при 2 свободных переменных.

Эксперимент на модельных данных

Описание данных:


- $n = 50$ — число признаков, $N_1 = 25$ — число объектов первого класса, $N_2 = 25$ — число объектов второго класса.
- Данные генерировались с равномерным распределением внутри двух гиперкубов, касающихся по одной из граней. Нормаль к этой грани направлена по вектору $(5, 4, 3, 2, 1, 0, \dots, 0)$.
- Таким образом, число реальных признаков, по которым выборка разделима, равно 5.

Обобщающая способность контролировалась двумя способами:

- На контрольной выборке из $N = 100000$ объектов, которая генерировалась тем же способом.
- С помощью Cross Validation.

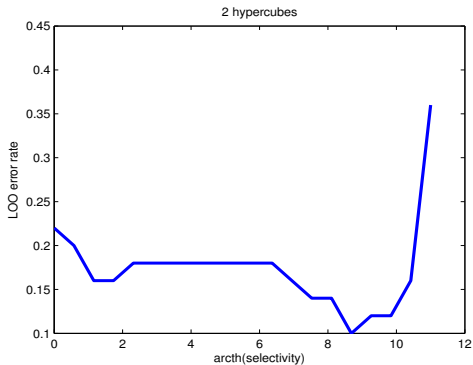
Результат на контрольной выборке

- В точке минимума ошибки алгоритм выделяет 4 признака из 5 правильных.
- Для целей масштабирования по оси X отложена не селективность μ , а величина $\text{arch}(\mu)$.



Результат с использованием Cross Validation

- В точке минимума ошибки алгоритм выделяет 13 признаков, содержащих 5 правильных.
- Отбрасываются 37 шумовых признаков.



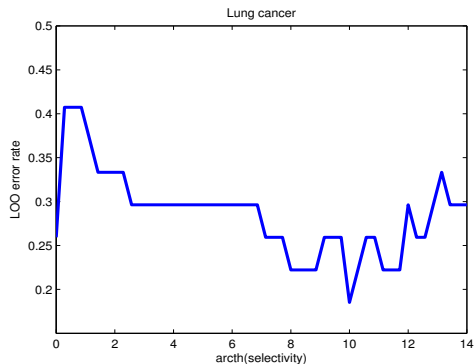
Эксперимент на реальных данных: Lung Cancer

Описание данных:

- $n = 55$ - число признаков, $N_1 = 9$ - число больных пациентов, $N_2 = 18$ - число здоровых пациентов.
- Источник данных: интернет-репозиторий задач машинного обучения UCI.

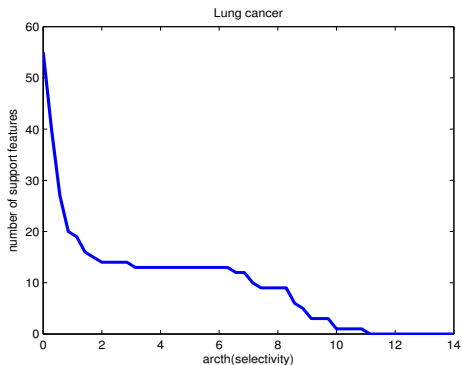
Результат с использованием Cross Validation

В точке минимума ошибки алгоритм выделяет 5 признаков.



Убывание числа признаков с увеличением селективности

При приближении селективности к 1 алгоритм отбрасывает все признаки.



Результаты

- Предложен регуляризатор l_2-l_1 с параметром селективности.
- Получена двойственная задача и выражение для решения исходной задачи через решение двойственной.
- Предложено два метода решения двойственной задачи: сведением к квадратичной задаче и с помощью обобщения метода SMO.
- Исследовано поведение метода на реальных и модельных данных с выбором селективности по Cross Validation.