

Ядерные методы

Виктор Китов
v.v.kitov@yandex.ru

МГУ им.Ломоносова, ф-т ВМиК, кафедра ММП.

I семестр 2015 г.

Содержание

- 1 Ridge регрессия
- 2 Kernel trick
- 3 Ядерные функции
- 4 Ядерное обобщение метода опорных векторов

Ridge регрессия

- Ridge регрессия - оптимизируемый критерий:

$$Q(\beta) = \sum_{n=1}^N (x_n^T \beta - y_n)^2 + \lambda \sum_{d=1}^D \beta_d^2 \rightarrow \min_{\beta}$$

- Условие стационарности:

$$\frac{dQ(\beta)}{d\beta} = 2 \sum_{n=1}^N (x_n^T \beta - y_n) x_n + 2\lambda\beta = 0 \quad (1)$$

- В векторной форме:

$$X^T (X\beta - Y) + \lambda\beta = 0$$

Ridge регрессия

- Решение прямой задачи:

$$X^T X + \lambda I \beta = X^T Y$$

$$\beta = (X^T X + \lambda I)^{-1} X^T Y$$

- Комментарий: $X^T X \succeq 0$ (неотрицательно определена), а $X^T X + \lambda I \succ 0$ (положительно определена), поэтому параметры ridge регрессии всегда однозначно идентифицируются.
- Сложность оценивания:
 - $X^T X + \lambda I$: $ND^2 + D$
 - $X^T Y$: DN
 - $(X^T X + \lambda I)^{-1}$: D^3
 - $(X^T X + \lambda I)^{-1} X^T Y$: D^2
 - Результирующая сложность оценивания:
 $O(ND^2 + D^3) = O(D^2(N + D))$.

Двойственное решение

Из векторная записи (1):

$$X^T (X\beta - Y) + \lambda\beta = 0$$

следует *двойственное решение* для вектора коэффициентов (линейная комбинация обучающих векторов):

$$\beta = \frac{1}{\lambda} X^T (Y - X\beta) = X^T \alpha \quad (2)$$

где

$$\alpha = \frac{1}{\lambda} (Y - X\beta) \quad (3)$$

называются *двойственными переменными*.

Прогнозирование:

$$\hat{y}(x) = x^T \beta = x^T X^T \alpha = \sum_{i=1}^N \alpha_i \langle x, x_i \rangle$$

Двойственное решение

Для нахождения α подставим (2) в (3):

$$\begin{aligned}\alpha &= \frac{1}{\lambda}(Y - X\beta) = \frac{1}{\lambda}(Y - XX^T\alpha) \\ (XX^T + \lambda I)\alpha &= Y \\ \alpha &= (XX^T + \lambda I)^{-1}Y\end{aligned}$$

Сложность оценивания модели :

$$XX^T + \lambda I: N^2D + N$$

$$(XX^T + \lambda I)^{-1}: N^3$$

$$(XX^T + \lambda I)^{-1}Y: N^2$$

Итоговая сложность обучения: $O(N^2D + N^3) = O(N^2(D + N))$.

Сложность прогнозирования $\hat{y}(x) = \langle x, \beta \rangle = \sum_{i=1}^N \alpha_i \langle x, x_i \rangle$:
 ND .

Преимущества двойственного решения

- Оптимальные α зависят только от скалярных произведений векторов (а не от полных признаковых представлений объектов):

$$\alpha = \left(\mathbf{X}\mathbf{X}^T + \lambda \mathbf{I} \right)^{-1} \mathbf{Y} = (\mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{Y}$$

где $\mathbf{G} \in \mathbb{R}^{N \times N}$ и $\{\mathbf{G}\}_{ij} = \langle \mathbf{x}_i, \mathbf{x}_j \rangle$ - \mathbf{G} называется *матрицей Грамма*.

- Прогноз также зависит только от скалярных произведений:

$$\hat{y}(x) = \sum_{i=1}^N \alpha_i \langle x, \mathbf{x}_i \rangle = \alpha^T \mathbf{v}$$

где $\mathbf{v} \in \mathbb{R}^N$ и $v_i = \langle x, \mathbf{x}_i \rangle$.

Преимущества

- Оценка модели становится вычислительно проще при $D > N$
 - можно переходить в признаковые пространства большой размерности, даже бесконечномерные.

Преимущество двойственного решения

Не нужно представление объекта в том признаковом пространстве, в котором работает модель - в том пространстве нужна только возможность вычислять скалярные произведения для любой пары объектов.

Содержание

- 1 Ridge регрессия
- 2 Kernel trick**
- 3 Ядерные функции
- 4 Ядерное обобщение метода опорных векторов

Kernel trick

Kernel trick

Определить не полное признаковое описание x , а только функцию вычисления скалярного произведения $K(x, x')$

- $\langle x, x' \rangle$ имеет сложность $O(D)$, а сложность вычисления $K(x, x')$ может быть меньше.

Комментарии

Kernel trick применим не только к ridge регрессии, но и к:

- методу K ближайших соседей
- K -средних, K -medoids (кластеризация)
- nearest medoid
- метод главных компонент (снижение размерности)
- метод опорных векторов
- многие другие

Когда исходное пространство объектов $\mathcal{X} = \mathbb{R}^M$, то всегда можно определить *линейное ядро*:

$$K(x, x') = \langle x, x' \rangle = \sum_{d=1}^D x_d x'_d$$

Характерные случаи применимости kernel trick

- признаковое пространство высокой размерности
 - все полиномы степени до M
 - Гауссово ядро $K(x, x') = e^{-\frac{1}{2\sigma^2} \|x-x'\|^2}$ соответствует признаковому пространству бесконечной размерности.
- сложно представить объекты векторами фиксированной длины
 - строки, множества, картинки, тексты, графы, 3D-структуры и т.д.
- существуют естественные определения скалярного произведения
 - строки: число совместно встречающихся подстрок
 - множества: размер общего подмножества
 - пример: для множеств S_1 и S_2 : $K(S_1, S_2) = 2^{|S_1 \cap S_2|}$ -ядро.
- скалярное произведение может быть эффективно посчитано

Преимущества kernel trick

- обобщение линейных методов на нелинейный случай
 - с сохранением вычислительной эффективности линейных методов
 - с сохранением преимуществ линейных методов
 - локальный оптимум является глобальным
 - нет локальных оптимумов=>меньше переобучение
- объекты для которых не существует векторных представлений фиксированной длины
- ускоренное вычисление скалярных произведений для высоких значений D

Содержание

- 1 Ridge регрессия
- 2 Kernel trick
- 3 Ядерные функции**
- 4 Ядерное обобщение метода опорных векторов

Определение ядра


- $x \in \mathcal{X}$ заменяется признаковым описанием $\phi(x)$ размерности D .
 - \mathcal{X} - пространство объектов (первичное представление, не обязательно \mathbb{R}^M)
 - Пример: $[x] \rightarrow [x, x^2, x^3]$

Ядро (Kernel)

Функция $K(x, x') : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$ является ядром, если найдется такое признаковое описание $\phi(x) : \mathcal{X} \rightarrow X$ что $K(x, x') = \langle \phi(x), \phi(x') \rangle$.

- $\langle x, x' \rangle$ определяется как $\langle \phi(x), \phi(x') \rangle = K(x, x')$
- Частные разновидности ядер:
 - $K(x, x') = K(x - x')$ - стационарные ядра (инвариантны к параллельным переносам)
 - $K(x, x') = K(\|x - x'\|)$ - радиальные базисные функции

Иллюстрация



Полиномиальное ядро

- Пример 1: пусть $D = 2$.

$$\begin{aligned} K(x, z) &= (x^T z)^2 = (x_1 z_1 + x_2 z_2)^2 = \\ &= x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 z_1 x_2 z_2 \\ &= \phi^T(x) \phi(z) \end{aligned}$$

где $\phi(x) = (x_1^2, x_2^2, \sqrt{2}x_1 x_2)$

- Пример 2: пусть $D = 2$.

$$\begin{aligned} K(x, z) &= (1 + x^T z)^2 = (1 + x_1 z_1 + x_2 z_2)^2 = \\ &= 1 + x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 z_1 + 2x_2 z_2 + 2x_1 z_1 x_2 z_2 \\ &= \phi^T(x) \phi(z) \end{aligned}$$

где $\phi(x) = (1, x_1^2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2, \sqrt{2}x_1 x_2)$

- В общем, для $D \geq 1$ $K(x, z) = (x^T z)^M$ соответствует расширению признакового пространства до всех мономов степени M , а $(1 + x^T z)^M$ - до всех мономов степени не выше M .

Свойства ядер

Теорема (Мерсер, упрощенная формулировка): Функция $K(x, x')$ является ядром тогда и только тогда, когда

- она симметрична: $K(x, x') = K(x', x)$
- она неотрицательно-определена (см. 2 эквивалентных определения ниже).
 - определение 1: для произвольной функции $g : X \rightarrow \mathbb{R}$

$$\int_X \int_X K(x, x') g(x) g(x') dx dx' \geq 0$$

- определение 2: для произвольного конечного набора объектов x_1, x_2, \dots, x_m матрица Грамма $\{K(x_i, x_j)\}_{i,j=1}^m \succeq 0$ (неотрицательно определена)

Построение новых ядер

- Обучение ядер (kernel learning) - отдельная область.
- Сложно доказывать неотрицательную определенность $K(x, x')$ в каждом новом случае.
- Новые ядра обычно строят из известных ядер, применяя преобразования сохраняющие свойство ядра:
- Известные ядра:
 - обычное скалярное определение $\langle x, x' \rangle$
 - константа $K(x, x') \equiv 1$
 - $x^T A x$ для любой $A \succeq 0$

Преобразования, сохраняющие свойство ядра


Если $K_1(x, x')$, $K_2(x, x')$ - произвольные ядра, $c > 0$ - константа, $q(\cdot)$ - полином с неотрицательными коэффициентами, $h(x)$ и $\varphi(x)$ - произвольные функции, отображающие $\mathcal{X} \rightarrow \mathbb{R}$ и $\mathcal{X} \rightarrow \mathbb{R}^M$ соответственно, то ядрами также являются:

- 1 $K(x, x') = cK_1(x, x')$
- 2 $K(x, x') = K_1(x, x')K_2(x, x')$
- 3 $K(x, x') = K_1(x, x') + K_2(x, x')$
- 4 $K(x, x') = K_1(\varphi(x), \varphi(x'))$
- 5 $K(x, x') = h(x)K_1(x, x')h(x')$
- 6 $K(x, x') = e^{K_1(x, x')}$

Часто используемые функции $K(x, x')$

$K(x, x')$	определение
линейная	$\langle x, x' \rangle$
полиномиальная	$(\gamma \langle x, x' \rangle + r)^d$
RBF	$\exp(-\gamma \ x - x'\ ^2)$
сигмоидальное	$\tanh(\gamma \langle x, y \rangle + r)$

- Линейная, полиномиальная и RBF функция являются ядрами Мерсера, а сигмоидальная - нет.



Дополнение

- Другие алгоритмы, допускающие обобщение через ядра: К-ближайших соседей, К-средних, К-medoids, nearest medoid, метод главных компонент, метод опорных векторов и многие другие..
- Определение расстояния через ядро:

$$\begin{aligned}\rho(x, x') &= \langle x - x', x - x' \rangle = \langle x, x \rangle + \langle x', x' \rangle - 2\langle x, x' \rangle \\ &= K(x, x) + K(x', x') - 2K(x, x')\end{aligned}$$

- Скалярное определение нормализованных векторов:

$$\left\langle \frac{\phi(x)}{\|\phi(x)\|}, \frac{\phi(x')}{\|\phi(x')\|} \right\rangle = \frac{\langle \phi(x), \phi(x') \rangle}{\sqrt{\langle \phi(x), \phi(x) \rangle} \sqrt{\langle \phi(x'), \phi(x') \rangle}} = \frac{K(x, x')}{\sqrt{K(x, x)K(x', x')}}$$

Содержание

- 1 Ridge регрессия
- 2 Kernel trick
- 3 Ядерные функции
- 4 Ядерное обобщение метода опорных векторов**

Линейный метод опорных векторов

- Решение для весовых коэффициентов:

$$w = \sum_{i \in SV} \alpha_i y_i x_i$$

- Дискриминантная функция

$$g(x) = \sum_{i \in SV} \alpha_i y_i \langle x_i, x \rangle + w_0$$

$$w_0 = \frac{1}{n_{\tilde{SV}}} \left(\sum_{i \in \tilde{SV}} y_i - \sum_{i \in \tilde{SV}} \sum_{j \in SV} \alpha_j y_j \langle x_i, x_j \rangle \right)$$

где $SV = \{i : y_i(x_i^T w + w_0) \leq 1\}$ - индексы всех опорных векторов, а $\tilde{SV} = \{i : y_i(x_i^T w + w_0) = 1\}$ - индексы граничных опорных векторов.





Ядерное обобщение


Дискриминантная функция:


$$g(x) = \sum_{i \in \mathcal{SV}} \alpha_i y_i K(x_i, x) + w_0$$


$$w_0 = \frac{1}{n_{\tilde{\mathcal{SV}}}} \left(\sum_{i \in \tilde{\mathcal{SV}}} y_i - \sum_{i \in \tilde{\mathcal{SV}}} \sum_{j \in \mathcal{SV}} \alpha_j y_j K(x_i, x_j) \right)$$


Области классов для ядерного обобщения





Линейное ядро - изменяемое C 


Линейное ядро - изменяемое C 


Линейное ядро - изменяемое C 

Линейное ядро - изменяемое C 


RBF ядро - изменяемое γ 

RBF ядро - изменяемое γ RBF kernel, $\gamma = 0.1, C = 1$ 


RBF ядро - изменяемое γ 

RBF ядро - изменяемое γ 


RBF ядро - изменяемое C




RBF ядро - изменяемое C




RBF ядро - изменяемое C




Полиномиальное ядро - изменяемое d




Полиномиальное ядро - изменяемое d





Полиномиальное ядро - изменяемое d





Полиномиальное ядро - изменяемое d

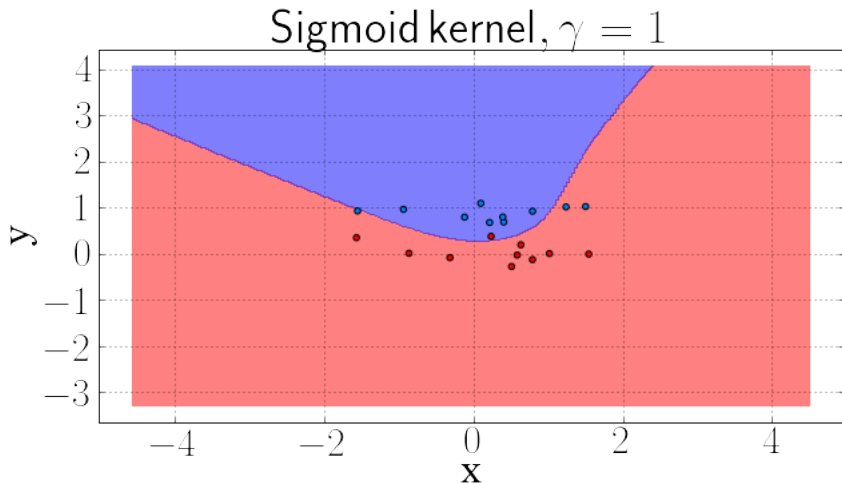


Полиномиальное ядро - изменяемое C 

Полиномиальное ядро - изменяемое C 

Полиномиальное ядро - изменяемое C 

Сигмоидальное ядро - изменяемое γ 

Сигмоидальное ядро - изменяемое γ 

Сигмоидальное ядро - изменяемое γ 

Сигмоидальное ядро - изменяемое C

