

Семинары по линейным классификаторам

Евгений Соколов
sokolov.evg@gmail.com

3 октября 2014 г.

1 Основные определения

Пусть $X \subset \mathbb{R}^d$ — пространство объектов, $Y = \{-1, +1\}$ — множество допустимых ответов, $X^\ell = (x_i, y_i)_{i=1}^\ell$ — обучающая выборка. Каждый объект $x \in X$ описывается вещественным вектором $(x_1, \dots, x_d) \in \mathbb{R}^d$.

Линейный классификатор определяется следующим образом:

$$a(x, w) = \text{sign}(\langle w, x \rangle + b) = \text{sign}\left(\sum_{j=1}^d w_j x_j + b\right),$$

где $w \in \mathbb{R}^d$ — вектор весов, $b \in \mathbb{R}$ — сдвиг (bias).

Если не сказано иначе, мы будем считать, что среди признаков есть константа, $x_0 = 1$. В этом случае нет необходимости вводить сдвиг b , и линейный классификатор можно задавать как

$$a(x, w) = \text{sign}\langle w, x \rangle.$$

Обучение линейного классификатора заключается в поиске вектора весов, на котором достигается минимум некоторого функционала качества:

$$w = \arg \min_{w \in \mathbb{R}^d} Q(w, X^\ell). \quad (1.1)$$

Наиболее логичным функционалом для задачи классификации является число неверно классифицированных объектов:

$$Q(w, X^\ell) = \sum_{i=1}^{\ell} [y_i a(x_i, w) < 0] \rightarrow \min_w.$$

У такого функционала, однако, есть большой недостаток — он не является дифференцируемым, из-за чего поиск оптимального вектора весов w становится крайне трудной задачей. Чтобы преодолеть эту проблему, оптимизируют гладкую верхнюю оценку на данный функционал:

$$Q(w, X^\ell) = \sum_{i=1}^{\ell} [y_i a(x_i, w) < 0] \leq \sum_{i=1}^{\ell} L(y_i a(x_i, w)) \rightarrow \min_w. \quad (1.2)$$

В качестве оценки $L(M)$ можно использовать, например, логистическую функцию потерь $L(M) = \log(1 + e^{-M})$.

2 Градиент функции

Как правило, оптимизационная задача (1.2) решается с помощью градиентных методов (или же методов, использующих как градиент, так и информацию о производных более высокого порядка).

Градиентом функции $f : \mathbb{R}^d \rightarrow \mathbb{R}$ называется вектор его частных производных:

$$\nabla f(x_1, \dots, x_d) = \left(\frac{\partial f}{\partial x_j} \right)_{j=1}^d.$$

§2.1 Свойства градиента

Градиент является направлением наискорейшего роста функции, а антиградиент (т.е. $-\nabla f$) — направлением наискорейшего убывания. Это ключевое свойство градиента, обосновывающее его использование в методах оптимизации.

Докажем данное утверждение. Пусть $v \in \mathbb{R}^d$ — произвольный вектор, лежащий на единичной сфере: $\|v\| = 1$. Пусть $x_0 \in \mathbb{R}^d$ — фиксированная точка пространства. Скорость роста функции в точке x_0 вдоль вектора v характеризуется производной по направлению $\frac{\partial f}{\partial v}$:

$$\frac{\partial f}{\partial v} = \frac{d}{dt} f(x_{0,1} + tv_1, \dots, x_{0,d} + tv_d) \Big|_{t=0}.$$

Из курса математического анализа известно, что данную производную сложной функции можно переписать следующим образом:

$$\frac{\partial f}{\partial v} = \sum_{j=1}^d \frac{\partial f}{\partial x_j} \frac{d}{dt} (x_{0,j} + tv_j) = \sum_{j=1}^d \frac{\partial f}{\partial x_j} v_j = \langle \nabla f, v \rangle.$$

Распишем скалярное произведение:

$$\langle \nabla f, v \rangle = \|\nabla f\| \|v\| \cos \varphi = \|\nabla f\| \cos \varphi,$$

где φ — угол между градиентом и вектором v . Таким образом, производная по направлению будет максимальной, если угол между градиентом и направлением равен нулю, и минимальной, если угол равен 180 градусам. Иными словами, производная по направлению максимальна вдоль градиента и минимальна вдоль антиградиента.

Покажем теперь, что градиент ортогонален линиям уровня. Пусть x_0 — некоторая точка, $S(x_0) = \{x \in \mathbb{R}^d \mid f(x) = f(x_0)\}$ — соответствующая линия уровня. Разложим функцию в ряд Тейлора на этой линии в окрестности x_0 :

$$f(x_0 + \varepsilon) = f(x_0) + \langle \nabla f, \varepsilon \rangle + o(\|\varepsilon\|),$$

где $x_0 + \varepsilon \in S(x_0)$. Поскольку $f(x_0 + \varepsilon) = f(x_0)$ (линия уровня же), получим

$$\langle \nabla f, \varepsilon \rangle = o(\|\varepsilon\|).$$

Поделим обе части на ε :

$$\left\langle \nabla f, \frac{\varepsilon}{\|\varepsilon\|} \right\rangle = o(1).$$

Устремим $\|\varepsilon\|$ к нулю. При этом вектор $\frac{\varepsilon}{\|\varepsilon\|}$ будет стремиться к касательной к линии уровня в точке x_0 . В пределе получим, что градиент ортогонален этой касательной.

§2.2 Векторное дифференцирование

При аналитическом вычислении градиента крайне полезны формулы векторного дифференцирования. Выведем простейшие из них.

Задача 2.1. Покажите, что

$$\nabla_x \langle a, x \rangle = a.$$

Решение. Найдем производную по j -й координате:

$$\frac{\partial}{\partial x_j} \langle a, x \rangle = \frac{\partial}{\partial x_j} \sum_{k=1}^d a_k x_k = a_j.$$

Значит, градиент равен a . ■

Задача 2.2. Покажите, что

$$\nabla_x \|x\|_2^2 = 2x.$$

Решение. Найдем производную по j -й координате:

$$\frac{\partial}{\partial x_j} \|x\|_2^2 = \frac{\partial}{\partial x_j} \sum_{k=1}^d x_k^2 = 2x_j.$$

Значит, градиент равен $2x$. ■

Задача 2.3. Покажите, что

$$\nabla_x \langle Ax, x \rangle = (A + A^T)x,$$

где $A \in \mathbb{R}^{d \times d}$.

Решение. Распишем интересующую нас функцию:

$$\begin{aligned} \langle Ax, x \rangle &= \sum_{j=1}^d (Ax)_j x_j = \sum_{j=1}^d \left(\sum_{k=1}^d a_{jk} x_k \right) x_j = \\ &= \sum_{j=1}^d \sum_{k=1}^d a_{jk} x_j x_k = \sum_{j=1}^d a_{jj} x_j^2 + \sum_{j \neq k} a_{jk} x_j x_k. \end{aligned}$$

Найдем частную производную по i -й координате:

$$\begin{aligned} \frac{\partial}{\partial x_i} \langle Ax, x \rangle &= \frac{\partial}{\partial x_i} \sum_{j=1}^d a_{jj} x_j^2 + \frac{\partial}{\partial x_i} \sum_{j \neq k} a_{jk} x_j x_k = \\ &= \frac{\partial}{\partial x_i} \sum_{j=1}^d a_{jj} x_j^2 + \frac{\partial}{\partial x_i} \left(\sum_{j \neq i} a_{ij} x_i x_j + \sum_{j \neq i} a_{ji} x_i x_j \right) = \\ &= 2a_{ii} x_i + \sum_{j \neq i} a_{ij} x_j + \sum_{j \neq i} a_{ji} x_j = \sum_{j=1}^d a_{ij} x_j + \sum_{j=1}^d a_{ji} x_j = \\ &= (Ax)_i + (A^T x)_i \end{aligned}$$

Получаем:

$$\nabla_x \langle Ax, x \rangle = Ax + A^T x = (A + A^T)x.$$

■

Задача 2.4. *Покажите, что*

$$\nabla_x \|Ax + b\|_2^2 = 2A^T(Ax + b).$$

Здесь $x \in \mathbb{R}^d$, $A \in \mathbb{R}^{m \times d}$, $b \in \mathbb{R}^m$.

Решение. Распишем норму:

$$\begin{aligned} \|Ax + b\|_2^2 &= \langle Ax + b, Ax + b \rangle = \langle Ax, Ax \rangle + 2\langle Ax, b \rangle + \langle b, b \rangle = \\ &= \langle A^T Ax, x \rangle + 2\langle x, A^T b \rangle + \langle b, b \rangle. \end{aligned}$$

Воспользуемся уже полученными нами формулами векторного дифференцирования:

$$\begin{aligned} \nabla_x \|Ax + b\|_2^2 &= \nabla_x \langle A^T Ax, x \rangle + \nabla_x 2\langle x, A^T b \rangle + \nabla_x \langle b, b \rangle = \\ &= (A^T A + A^T A)x + 2A^T b = 2A^T Ax + 2A^T b = \\ &= 2A^T(Ax + b). \end{aligned}$$

■

3 Геометрия линейных классификаторов

Уравнение $\langle w, x \rangle = 0$ задает гиперплоскость вектором нормали w . Если вектор x находится по одну сторону этой гиперплоскости, то он относится к классу $+1$, иначе к классу -1 .

Задача 3.1. *Пусть гиперплоскость проходит через начало координат и задана уравнением $\langle w, x \rangle = 0$. Покажите, что евклидово расстояние между ней и точкой x_0 равно*

$$\frac{|\langle w, x_0 \rangle|}{\|w\|}.$$

Решение. Искомое расстояние можно найти как решение задачи условной оптимизации

$$\begin{cases} \|x - x_0\|_2^2 \rightarrow \min_{x \in \mathbb{R}^d} \\ \langle w, x \rangle = 0 \end{cases} \quad (3.1)$$

Здесь мы ищем такую точку на прямой, что расстояние от нее до x_0 минимально; иными словами, мы ищем проекцию. Расстояние от точки до ее проекции на прямую и является расстоянием от точки до прямой.

Выпишем лагранжиан:

$$\mathcal{L} = \|x - x_0\|^2 + \lambda \langle w, x \rangle.$$

Найдем его градиент по x и приравняем его нулю:

$$\nabla_x \mathcal{L} = 2(x - x_0) + \lambda w = 0.$$

Это условие, вкпе с ограничением $\langle w, x \rangle = 0$, является необходимым условием для решения задачи (3.1).

Выразим отсюда x : $x = x_0 - \frac{\lambda w}{2}$. Подставим его в ограничение:

$$\langle w, x_0 - \frac{\lambda w}{2} \rangle = \langle w, x_0 \rangle - \frac{\lambda}{2} \langle w, w \rangle = \langle w, x_0 \rangle - \frac{\lambda}{2} \|w\|^2 = 0.$$

Отсюда получаем:

$$\lambda = \frac{2\langle w, x_0 \rangle}{\|w\|^2}.$$

Подставим обратно в выражение для x :

$$x = x_0 - \frac{\lambda w}{2} = x_0 - \langle w, x_0 \rangle \frac{w}{\|w\|^2}.$$

Мы нашли проекцию точки x_0 на прямую. Найдем теперь расстояние:

$$\|x - x_0\|_2 = \|\langle w, x_0 \rangle \frac{w}{\|w\|^2}\| = |\langle w, x_0 \rangle| \frac{\|w\|}{\|w\|^2} = \frac{|\langle w, x_0 \rangle|}{\|w\|}.$$

■

Таким образом, если вектор весов нормирован, то скалярное произведение объекта на этот вектор равно расстоянию от объекта до разделяющей гиперплоскости. Это объясняет, почему величина отступа $M(x_i) = \langle w, x_i \rangle y_i$ характеризует уверенность классификатора в объекте: чем больше отступ, тем дальше от гиперплоскости расположен объект.

Смысл полученной формулы легко понять, если рассмотреть двумерное пространство. Рассмотрим прямоугольный треугольник, образованный векторами w и x_0 (см. рис. 1). Для косинуса угла между ними выполнено

$$\cos(w, x_0) = \frac{\|\text{proj}_w(x_0)\|}{\|x_0\|},$$

где $\text{proj}_w(x_0)$ — проекция x_0 на w . Длина же данной проекции равна расстоянию от x_0 до прямой с нормалью w . Значит, расстояние можно записать как

$$\|\text{proj}_w(x_0)\| = \|x_0\| \cos(w, x_0) = \frac{\|x_0\| \|w\| \cos(w, x_0)}{\|w\|} = \frac{|\langle w, x_0 \rangle|}{\|w\|},$$

то есть его можно вычислять по полученной нами формуле.




Рис. 1. Вычисление расстояния от точки до прямой.

4 Методы оптимизации

Пусть $Q(w)$ — функционал, представимый в виде суммы n функций:

$$Q(w) = \sum_{i=1}^n q_i(w).$$

В таком виде, например, может быть представлен функционал в линейных методах (1.2). Отдельные функции $q_i(w)$ будут соответствовать ошибкам на отдельных объектах.

Наиболее известным является метод *градиентного спуска* (full gradient, FG) [1], в котором выбирается начальное приближение w^0 , и затем до сходимости делаются шаги по антиградиенту:

$$w^k = w^{k-1} - \eta_k \nabla Q(w^{k-1}).$$

Если функционал $Q(w)$ выпуклый, гладкий и имеет минимум w^* , то имеет место следующая оценка сходимости:

$$Q(w^k) - Q(w^*) = O(1/k).$$

Если функционал состоит из большого числа слагаемых (т.е. n велико), то градиентный спуск может оказаться слишком трудоемким. В этих случаях можно воспользоваться методом *стохастического градиента* (stochastic gradient) [2]:

$$w^k = w^{k-1} - \eta_k \nabla q_{i_k}(w^{k-1}),$$

где i_k — случайно выбранный номер слагаемого из функционала. Для выпуклого и гладкого функционала может быть получена следующая оценка:

$$\mathbb{E} [Q(w^k) - Q(w^*)] = O(1/\sqrt{k}).$$

Таким образом, метод стохастического градиента имеет менее трудоемкие итерации по сравнению с полным градиентом, но и скорость сходимости у него существенно меньше.

Недавно был предложен метод *среднего стохастического градиента* (stochastic average gradient) [3], который сочетает в себе быстроту итераций стохастического градиента и высокую скорость сходимости полного градиента. Перед началом итераций в нем выбирается начальное приближение w^0 , и инициализируются вспомогательные переменные y_i^0 , соответствующие градиентам слагаемых функционала:

$$y_i^0 = \nabla q_i(w^0), \quad i = 1, \dots, n.$$

На k -й итерации выбирается случайное слагаемое i_k и обновляются вспомогательные переменные:

$$y_i^k = \begin{cases} \nabla q_i(w^{k-1}), & \text{если } i = i_k; \\ y_i^{k-1} & \text{иначе.} \end{cases}$$

Иными словами, пересчитывается один из градиентов слагаемых. Наконец, делается градиентный шаг:

$$w^k = w^{k-1} - \eta_k \sum_{i=1}^n y_i^k.$$

Данный метод имеет такой же порядок сходимости для выпуклых и гладких функционалов, как и обычный градиентный спуск:

$$\mathbb{E} [Q(w^k) - Q(w^*)] = O(1/k).$$

§4.1 Выбор параметров

Параметрами градиентного спуска являются начальное приближение w^0 и темп обучения (или длина шага) η_t . Выбор начального приближения был подробно обсужден на лекции, мы же сосредоточимся на выборе темпа обучения.

Если на каждом шаге выбирать оптимальный темп обучения, то есть полагать его равным решению задачи

$$Q(w^t - \eta_t \nabla Q(w^t)) \rightarrow \min_{\eta_t},$$

то получим метод *наискорейшего градиентного спуска*.

Задача 4.1. Рассмотрим функционал, оптимизируемый на одном шаге стохастического градиентного спуска:

$$Q(w) = (\langle w, x_i \rangle - y_i)^2.$$

Шаг итерационного процесса имеет вид

$$w^{t+1} = w^t - \eta_t (\langle w^t, x_i \rangle - y_i) x_i$$

(убедитесь, что он действительно такой). Покажите, что в наискорейшем спуске длина шага выбирается как $\eta_t = \frac{1}{\|x_i\|^2}$.

Решение. Длина шага выбирается как решение задачи

$$(\langle w^t - \eta_t(\langle w^t, x_i \rangle - y_i)x_i, x_i \rangle - y_i)^2 \rightarrow \min_{\eta_t}.$$

Найдем производную и приравняем ее нулю:

$$\begin{aligned} \frac{d}{d\eta_t} (\langle w^t - \eta_t(\langle w^t, x_i \rangle - y_i)x_i, x_i \rangle - y_i)^2 &= \\ &= \frac{d}{d\eta_t} (\langle w^t, x_i \rangle - \eta_t(\langle w^t, x_i \rangle - y_i)\langle x_i, x_i \rangle - y_i)^2 = \\ &= 2(\langle w^t, x_i \rangle - \eta_t(\langle w^t, x_i \rangle - y_i)\langle x_i, x_i \rangle - y_i)(\langle w^t, x_i \rangle - y_i)\langle x_i, x_i \rangle = \\ &= 0 \end{aligned}$$

Выразим отсюда η_t :

$$\eta_t = \frac{(\langle w^t, x_i \rangle - y_i)\|x_i\|^2}{(\langle w^t, x_i \rangle - y_i)\|x_i\|^4} = \frac{1}{\|x_i\|^2}.$$

■

Покажем, что если градиент функционала ограничен по норме, т.е. $\|\nabla Q\| \leq D$, то необходимым условием сходимости градиентного спуска к решению является

$$\sum_{t=0}^{\infty} \eta_t = \infty.$$

Расписывая выражение для вектора весов w^{t+1} на $(t+1)$ -м шаге, получим

$$w^{t+1} = w^0 - \sum_{s=0}^t \eta_s \nabla Q(w^s).$$

Оценим расстояние между w^{t+1} и w^0 :

$$\|w^{t+1} - w^0\| = \left\| \sum_{s=0}^t \eta_s \nabla Q(w^s) \right\| \leq \sum_{s=0}^t \eta_s \|\nabla Q(w^s)\| \leq D \sum_{s=0}^t \eta_s.$$

Предположим, что ряд шагов $\sum_{t=0}^{\infty} \eta_t$ сходится, тогда все его частичные суммы ограничены некоторой константой S . Получаем, что

$$\|w^{t+1} - w^0\| \leq DS,$$

то есть расстояние между начальным приближением и *любой* точкой, полученной итерационным процессом, ограничено. Значит, если начальное приближение будет отстоять от решения больше, чем на DS , то градиентный спуск не сойдется к решению.

Масштабирование признаков. Для градиентного спуска крайне важно, чтобы признаки имели одинаковый масштаб. Если это не так, то скорость сходимости метода значительно уменьшается.

Также проблемы могут возникнуть, если один из признаков принимает большие значения, а у функции потерь имеется горизонтальная асимптота. Тогда производная функции потерь на большом значении скалярного произведения $\langle w, x \rangle$ будет близка к нулю, и градиентный спуск застрянет на данном значении вектора параметров w . Это явление называется «параличом» оптимизационного метода. Чтобы избежать его, следует нормировать все признаки на отрезок $[0, 1]$ или $[-1, 1]$.




Рис. 2. Линии уровня функционала качества, а также ограничения, задаваемые L_2 и L_1 -регуляризаторами.

5 Регуляризация

В некоторых случаях (признаков больше чем объектов, коррелирующие признаки) оптимизационная задача $Q(w) \rightarrow \min$ может иметь бесконечное число решений, большинство которых являются переобученными и плохо работают на тестовых данных. Действительно, пусть в выборке есть линейно зависимые признаки. Это по определению означает, что существует такой вектор v , что для любого объекта x выполнено $\langle v, x \rangle = 0$. Допустим, мы нашли оптимальный вектор весов w для линейного классификатора. Но тогда классификаторы с векторами $w + \alpha v$ будут давать *точно такие же* ответы на всех объектах, поскольку

$$\langle w + \alpha v, x \rangle = \langle w, x \rangle + \underbrace{\alpha \langle v, x \rangle}_{=0} = \langle w, x \rangle.$$

Это значит, что метод оптимизации может найти решение со сколько угодно большими весами. Такие решения не очень хороши, поскольку классификатор будет чувствителен к крайне маленьким изменениям в признаках объекта, а значит, переобучен.

Данная проблема устраняется путем добавления к функционалу *регуляризатора*, который штрафует за слишком большие значения весов:

$$Q_\tau(w) = Q(w) + \tau R(w).$$

Наиболее распространенными являются L_2 и L_1 -регуляризаторы:

$$\|w\|_2 = \sum_{i=1}^d w_i^2,$$

$$\|w\|_1 = \sum_{i=1}^d |w_i|.$$

Особенностью L_1 -регуляризатора является то, что он зануляет часть весов, осуществляя тем самым отбор признаков. Попробуем понять, почему это так.

Можно показать, что если функционал $Q(w)$ является выпуклым, то задача безусловной минимизации функции $Q(w) + \tau \|w\|_1$ эквивалентна задаче условной оп-

тимизации

$$\begin{cases} Q(w) \rightarrow \min_w \\ \|w\|_1 \leq C \end{cases}$$

для некоторого C . На рис. 2 изображены линии уровня функционала $Q(w)$, а также множество, определяемое ограничением $\|w\|_1 \leq C$. Решение определяется точкой пересечения допустимого множества с линией уровня. В большинстве случаев эта точка будет лежать на одной из вершин ромба, что соответствует решению с одной ненулевой компонентой.

Список литературы

- [1] *Cauchy, M. A.* (1847). Méthode générale pour la résolution des systèmes d'équations simultanées. // Comptes rendus hebdomadaires des séances de l'Académie des sciences, 25, p. 536-538.
- [2] *Robbins, H., Monro S.* (1951). A stochastic approximation method. // Annals of Mathematical Statistics, 22 (3), p. 400-407.
- [3] *Schmidt, M., Le Roux, N., Bach, F.* (2013). Minimizing finite sums with the stochastic average gradient. // Arxiv.org.