



Phystech@DataScience

Блок 2: линейные модели



Регуляризация

Классификация

Задача классификации

Логистическая регрессия

Градиентный спуск



Проблема: мультиколлинеарность

Мультиколлинеарность — наличие большого числа *линейно-зависимых* признаков.

Пример: среди признаков много таких, которые связаны с размером котика. Они все зависят друг от друга и несут *избыточную* информацию.

В модели линейной регрессии:

если для $\varepsilon = y - \hat{y}$ матрица ковариаций $\Sigma = \sigma^2 I_n$, то $D\hat{\theta} = \sigma^2(X^T X)^{-1}$.

Если признаки мультиколлинеарны, то $X^T X$ почти вырождена и дисперсия огромна.

Решение: регуляризация.



Ridge-регрессия

Задача МНК:

$$\|Y - X\theta\|_2 \rightarrow \min_{\theta}$$

Задача Ridge-регрессии:

$$\|Y - X\theta\|_2 + \lambda\|\theta\|_2 \rightarrow \min_{\theta}, \lambda > 0$$

Ограничиваем коэффициенты, не позволяем им «разбрасываться».

Замечание. Предварительно необходимо

- ▶ **центрировать** отклик $Y := Y - \bar{Y}$ или не накладывать ограничение на коэффициент при константе;
- ▶ **стандартизовать** признаки — вычесть среднее, поделить на корень из дисперсии.



Решение задачи

Решением задачи является

$$\hat{\theta} = (X^T X + \lambda I_d)^{-1} X^T Y$$

За счет добавки λI_d матрица стала менее вырожденной.

Вопрос в бот: посмотрите на формулу и скажите, почему признаки **ОБЯЗАТЕЛЬНО** надо стандартизировать?

У них могут быть разные размерности и масштаб!

Свойства

- ▶ $\lambda = 0 \implies$ МНК; $\lambda = \infty \implies \hat{\theta} = 0$;
- ▶ При $\lambda \geq 0$ решение $\exists!$;
- ▶ $\hat{\theta}$ может быть найдена *итеративными* методами;
- ▶ Пусть $E\varepsilon = 0$. Оценка смещенная $E\hat{\theta} = (X^T X + \lambda I_d)^{-1} X^T X \theta$;
- ▶ Пусть $D\varepsilon = \sigma^2 I_n$. Дисперсия уменьшилась:
 $D\hat{\theta} = \sigma^2 (X^T X + \lambda I_d)^{-1} X^T X (X^T X + \lambda I_d)^{-1}$



Lasso-регрессия

Задача МНК:

$$\|Y - X\theta\|_2 \rightarrow \min_{\theta}$$

Задача Lasso-регрессии:

$$\|Y - X\theta\|_2 + \lambda \|\theta\|_1 \rightarrow \min_{\theta}, \lambda > 0,$$

$$\|\theta\|_1 = |\theta_1| + |\theta_2| + \dots + |\theta_d|.$$

Свойства

- ▶ Решается **только** итеративными методами;
- ▶ Lasso-регрессия зануляет коэффициенты с ростом λ , может использоваться для отбора признаков.



Регуляризация

Классификация

Задача классификации

Логистическая регрессия

Градиентный спуск

Классификация

\mathcal{X} — пространство объектов,

\mathcal{Y} — конечное множество классов.

Истинное правило классификации:

неизвестная функция $f : \mathcal{X} \rightarrow \mathcal{Y}$.

Пространство \mathcal{X} разбивается на подпространства (*decision regions*)

$$\mathcal{X}_y = \{x \in \mathcal{X} \mid f(x) = y\},$$

границы которых называются *разделяющими поверхностями* (*decision surfaces*).





Классификация

Часто $\mathcal{X} \subset \mathbb{R}^d$, в т.ч. могут быть *категориальные*.

Типы классификации

1. *Двухклассовая*.

$$\mathcal{Y} = \{0, 1\} \text{ или } \mathcal{Y} = \{-1, 1\}.$$

2. *Многоклассовая*.

$$\mathcal{Y} = \{1, \dots, K\} \text{ или } \mathcal{Y} = \{(1, 0, \dots, 0), (0, 1, \dots, 0), \dots, (0, 0, \dots, 1)\}.$$

Задача классификации:

предложить **оценку** $\hat{f} : \mathcal{X} \rightarrow \mathcal{Y}$ правила классификации на основе обуч. выборки $(x_1, Y_1), \dots, (x_n, Y_n)$, где $x_i = (x_{i1}, \dots, x_{id}) \in \mathcal{X}$, $Y_i \in \mathcal{Y}$, как можно точнее приближающую неизвестное правило классиф-ции.

Оценку правила классификации чаще будем называть **моделью**.



Вероятностная природа

Часто предполагается случайная принадлежность классу:
функция f при повторении эксперимента может отнести один и тот же объект $x \in \mathcal{X}$ как одному классу, так и к другому.

\implies имеет смысл **предсказывать вероятность** $P_x(Y = y)$
принадлежности объекта x каждому из классов.

Точечная оценка: $\arg \max_{y \in \mathcal{Y}} P_x(Y = y)$

Если классы неравнозначны:

$\arg \max_{y \in \mathcal{Y}} [w_y P_x(Y = y)],$

w_y — **приоритетность класса**

Примеры:

1. $P(Y = 0 \mid X = x_2) = 0.95, \quad P(Y = 1 \mid X = x_2) = 0.05$
Уверенное предсказание в пользу класса 0.

2. $P(Y = 0 \mid X = x_1) = 0.55, \quad P(Y = 1 \mid X = x_1) = 0.45$
Модель не уверена в предсказании.





Линейные модели


$y(x) = \theta^T x$ — линейная модель регрессии.

Линейная модель в классификации:

Разделяющая поверхность — линейная *гиперплоскость* в пр-ве \mathcal{X} .

В многоклассовом случае — при дополнении до гиперплоскости.

Например, при $\mathcal{Y} = \{-1, 1\}$ линейна модель $y(x) = \text{sign}(\theta^T x)$.



Замечание

Исходное пр-во признаков может быть предварительно преобразовано с помощью нелинейных функций, в частности можно включить константный признак. В таком случае разделяющая поверхность лин. классификатора *не будет* линейной в исходном пространстве.



Регуляризация

Классификация

Задача классификации

Логистическая регрессия

Градиентный спуск



Логистическая регрессия

Пространство объектов $x \in \mathcal{X} \subset \mathbb{R}^d$.


Множество классов $\mathcal{Y} = \{0, 1\}$.

Класс объекта x имеет распределение $Bern(p(x))$, $p(x) \in [0, 1]$.

Предположение:


$$p_{\theta}(x) = \sigma(\theta^T x),$$

где $\sigma(z) = \frac{1}{1+e^{-z}}$ — логистическая сигмоида.





Логистическая регрессия



Разделяющая поверхность $\{p_{\theta}(x) = 1/2\} = \{\theta^T x = 0\}$ линейна, а значит логистическая регрессия является линейным классификатором.

Чем больше значение $\theta^T x$, тем более вероятен класс 1.



Свойства

Свойства:

1. $\sigma(-z) = 1 - \sigma(z)$. При $z = \theta^T x$ это — вероятность класса 0;
2. Обратная функция $z(s) = \ln \frac{s}{1-s}$ — **логит-функция**;
3. $\frac{d\sigma}{dz} = \sigma(z)(1 - \sigma(z))$.



Обучение

Пусть дана обучающая выборка $(x_1, Y_1), \dots, (x_n, Y_n)$, где $x_i = (x_{i1}, \dots, x_{id}) \in \mathcal{X}$ и случайный класс $Y_i \sim \text{Bern}(p_\theta(x_i))$.

Функция правдоподобия:

$$L_Y(\theta) = \prod_{i=1}^n p_\theta(x_i)^{Y_i} (1 - p_\theta(x_i))^{1-Y_i}$$

Что это за зверь? Вспомним формулу Бернулли: $P_n^k = C_n^k p^k (1-p)^{n-k}$

Пусть среди Y_i ровно k единиц. Если выборка **уже получена**, то индексы от 1 до n фиксированы, и C_n^k не нужно.

Функция правдоподобия **отражает вероятность получить такую реализацию!**

Подробности уже этой весной, не пропустите!



Обучение

$(x_1, Y_1), \dots, (x_n, Y_n)$ – реализация обучающей выборки,

$x_i = (x_{i1}, \dots, x_{id}) \in \mathcal{X}$

$Y_i \sim \text{Bern}(p_\theta(x_i))$ – случайный класс.

Функция правдоподобия для полученных чисел:

$$L_Y(\theta) = \prod_{i=1}^n p_\theta(x_i)^{Y_i} (1 - p_\theta(x_i))^{1-Y_i}$$

Фиксируем какое-нибудь θ .

Чем **больше** $L_Y(\theta)$, тем **«правдоподобнее»** это самое θ .

Будем **максимизировать** $L_Y(\theta)$ численно с помощью *градиентного подъема*.



Регуляризация

Классификация

Задача классификации

Логистическая регрессия

Градиентный спуск



Градиентный спуск

Пусть задача оптимизации имеет вид

$$f(\theta) \rightarrow \min_{\theta},$$

где $f(\theta)$ — дифференцируемая функция;

Итеративные методы оптимизации последовательно приближают текущее значение параметра θ к оптимальному θ^* .

Наблюдение (матан 1 курс): В малой окрестности точки направление скорейшего роста функции — ее **градиент** $\nabla_{\theta} f(\theta)$, направление скорейшего убывания — **антиградиент** $-\nabla_{\theta} f(\theta)$.



Градиентный спуск

Итерация:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} f(\theta_t).$$

Антиградиент вычитается с заданным малым коэффициентом η , который часто называют коэффициентом скорости обучения или **learning rate**.

Подбор η осуществляется пользователем.

Критерии останова:

1. Лимит на число итераций.
2. Early stopping. Не происходит уменьшения $f(\theta)$ в течение какого-то зафиксированного числа шагов.
3. Ограничение на норму невязки.

Норма невязки: $\|f(\theta_{t+1}) - f(\theta_t)\|$ становится ниже порога.



Максимизация $\ell_Y(\theta)$

$$\ell_Y(\theta) = \log L_Y(\theta) = \sum_{i=1}^n [Y_i \log \sigma(\theta^T x_i) + (1 - Y_i) \log (1 - \sigma(\theta^T x_i))]$$

Ее производная равна

$$\frac{\partial \ell_Y(\theta)}{\partial \theta} = \sum_{i=1}^n [Y_i - \sigma(\theta^T x_i)] x_i.$$

Получаем формулу градиентного подъема:

$$\theta_{t+1} = \theta_t + \eta \underbrace{\sum_{i=1}^n [Y_i - \sigma(\theta_t^T x_i)] x_i}_{\nabla_{\theta} f(\theta_t)}$$



Максимизация $\ell_Y(\theta)$

Можно также проводить **стохастический** градиентный подъем (спуск), выбирая случайный индекс i :

$$\theta_{t+1} = \theta_t + \eta [Y_i - \sigma(\theta_t^T x_i)] x_i$$

Вектор параметров сдвигается вдоль направления выбранного объекта x_i настолько, насколько модель ошибается на этом объекте.

Обозначения:

- ▶ Градиентный спуск — Gradient descent — GD;
- ▶ Стохастический градиентный спуск — Stochastic GD — SGD.

Компромисс между ними – Batch gradient descent (BGD), когда градиент на очередном шаге считается по *подмножеству* выборки (т.е. по батчу).



Переобучение модели

Пусть

- ▶ Классы линейно разделимы;
- ▶ Среди признаков есть константа;
- ▶ $\theta : \{\theta^T x = 0\}$ в точности разделяет два класса.

Тогда $\forall c > 0$ $\{c\theta^T x = 0\}$ в точности разделяет два класса.

Но $L_Y(c\theta) = \prod_{i=1}^n \sigma(c\theta^T x_i)^{Y_i} (1 - \sigma(c\theta^T x_i))^{1-Y_i} \rightarrow 1$ при $c \rightarrow \infty$.

При конечном θ максимум функции правдоподобия **не достигается**.

Проблемы

- ▶ Предсказания вероятностей классов близки к 0 или 1, что не информативно при решении реальных задач.
- ▶ Может быть выбрана произвольная гиперплоскость, в точности разделяющая два класса. При разных запусках один и тот же объект между классами может относиться с вероятностью 1 как к одному классу, так и к другому.



В качестве решения проблемы обычно используют *регуляризацию*.



ВСЁ!