

Н. Ю. Золотых

Задачи по машинному обучению

Версия: 15 сентября 2020 г.

Нижний Новгород
2013, 2018, 2019, 2020

1 Матричное дифференцирование

1. Пусть $g : \mathbf{R}^n \rightarrow \mathbf{R}^m$, $x \in \mathbf{R}^n$. Матрицей Якоби называется матрица

$$\frac{\partial g}{\partial x} = \begin{pmatrix} \frac{\partial g_1}{\partial x_1} & \frac{\partial g_1}{\partial x_2} & \cdots & \frac{\partial g_1}{\partial x_n} \\ \frac{\partial g_2}{\partial x_1} & \frac{\partial g_2}{\partial x_2} & \cdots & \frac{\partial g_2}{\partial x_n} \\ \ddots & \ddots & \ddots & \ddots \\ \frac{\partial g_m}{\partial x_1} & \frac{\partial g_m}{\partial x_2} & \cdots & \frac{\partial g_m}{\partial x_n} \end{pmatrix}.$$

В частности, если $m = 1$ (т. е. $g(x)$ — скалярная функция векторного аргумента x), то $\frac{\partial g}{\partial x}$ — градиент функции g .

Доказать, что

- 1) если $a \in \mathbf{R}^n$, $x \in \mathbf{R}^n$, то $\frac{\partial(a^\top x)}{\partial x} = a$;
- 2) если $A \in \mathbf{R}^{m \times n}$, $x \in \mathbf{R}^n$, то $\frac{\partial(Ax)}{\partial x} = A$;
- 3) если $A \in \mathbf{R}^{n \times n}$, $x \in \mathbf{R}^n$, то $\frac{\partial(x^\top Ax)}{\partial x} = (A + A^\top)x$; в частности, если $A^\top = A$, то $\frac{\partial(x^\top Ax)}{\partial x} = 2Ax$;
- 4) если $x \in \mathbf{R}^n$, то $\frac{\partial \|x\|^2}{\partial x} = 2x$;
- 5) если g — скалярная функция и под $g(x)$ понимается применение функции g к каждой компоненте вектора $x \in \mathbf{R}^n$, то

$$\frac{\partial g(x)}{\partial x} = \text{diag}(g'(x)),$$

где $\text{diag}(a)$ — диагональная матрица с диагональю a ;

- 6) если $h : \mathbf{R}^n \rightarrow \mathbf{R}^m$, $g : \mathbf{R}^m \rightarrow \mathbf{R}^p$, $x \in \mathbf{R}^n$, то

$$\frac{\partial g(h(x))}{\partial x} = \frac{\partial g(h(x))}{\partial h} \frac{\partial h(x)}{\partial x}.$$

2 Линейная регрессия

Пример 1. По обучающей выборке

| | | | | | |
|-----|----|----|---|---|---|
| x | -1 | 0 | 0 | 1 | 2 |
| y | 1 | -2 | 1 | 7 | 8 |

методом наименьших квадратов построить модель вида $f(x) = \beta_0 + \beta_1 x + \beta_2 x^2$.

Решение: Составляем матрицу \mathbf{X} и вектор \mathbf{y} :

$$\mathbf{X} = \begin{pmatrix} 1 & -1 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} 1 \\ -2 \\ 1 \\ 7 \\ 8 \end{pmatrix}.$$

Имеем

$$\mathbf{X}^\top \mathbf{X} = \begin{pmatrix} 5 & 2 & 6 \\ 2 & 6 & 8 \\ 6 & 8 & 18 \end{pmatrix}, \quad \mathbf{X}^\top \mathbf{y} = \begin{pmatrix} 15 \\ 22 \\ 40 \end{pmatrix}.$$

Решая систему нормальных уравнений $\mathbf{X}^\top \mathbf{X}\beta = \mathbf{X}^\top \mathbf{y}$, находим

$$\beta = \begin{pmatrix} 1 \\ 2 \\ 1 \end{pmatrix}$$

Таким образом, нашли модель $1 + 2x + x^2$ (синяя линия на графике).

Пример 2. Построить модель того же вида методом ридж-регрессии с параметром регуляризации $\lambda = 2$.


Решение: Для $\lambda = 2$ получаем

$$\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I} = \begin{pmatrix} 7 & 2 & 6 \\ 2 & 8 & 8 \\ 6 & 8 & 20 \end{pmatrix}.$$

Решая регуляризованную систему нормальных уравнений $(\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I})\beta = \mathbf{X}^\top \mathbf{y}$, находим

$$\beta = \begin{pmatrix} 21/31 \\ 81/62 \\ 79/62 \end{pmatrix}.$$

Таким образом, нашли модель $\frac{21}{31} + \frac{81}{62}x + \frac{79}{62}x^2 = 0.6774 + 1.3065x + 1.2742x^2$ (красная линия на графике).



Задачи для самостоятельного решения

2. Пользуясь № 1, найдите градиент $\frac{\partial g(\beta)}{\partial \beta}$ и гессиан $\frac{\partial^2 g(\beta)}{\partial \beta^\top \partial \beta}$ функции $g(\beta) = \|\mathbf{X}\beta - \mathbf{y}\|^2$. Выведите отсюда, что решение линейной задачи наименьших квадратов $\hat{\beta} = \operatorname{argmin} \|\mathbf{X}\beta - \mathbf{y}\|^2$ является решением нормальной системы линейных уравнений $\mathbf{X}^\top \mathbf{X}\beta = \mathbf{X}^\top \mathbf{y}$.

3. Даны обучающая выборка

| | | | | | |
|-----|---|---|---|---|----|
| x | 1 | 1 | 0 | 0 | -1 |
| y | 4 | 4 | 0 | 2 | 6 |

- 1) изобразить точки;
 - 2) методом наименьших квадратов построить модель вида $f(x) = \beta_0 + \beta_1 x + \beta_2 x^2$; построить график этой функции;
 - 3) построить модель того же вида методом ридж-регрессии с параметром регуляризации $\lambda = 1$; построить график этой функции.
- Замечание: при ручных вычислениях по методу наименьших квадратов рекомендуется составить систему $\mathbf{X}^\top \mathbf{X} \boldsymbol{\beta} = \mathbf{X}^\top \mathbf{y}$ и решить ее. Регуляризованная система: $(\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I}) \boldsymbol{\beta} = \mathbf{X}^\top \mathbf{y}$, где \mathbf{I} — единичная матрица.
4. Рассмотрим задачу восстановления регрессии, в которой \mathbf{y} распределен согласно нормальному закону $N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$, а $\boldsymbol{\beta}$ имеет априорное распределение $N(0, \tau \mathbf{I})$. Найти апостериорное распределение для $\boldsymbol{\beta}$. Доказать, что $\boldsymbol{\beta}^{\text{ridge}}$ есть его математическое ожидание. Найти связь между параметром регуляризации λ и дисперсиями τ , σ^2 .
 5. Показать, что процедура гребневой регрессии эквивалентна обычному методу наименьших квадратов, примененному к расширенным данным: к центрированной матрице \mathbf{X} дописывается матрица $\sqrt{\lambda} \mathbf{I}$, к вектору \mathbf{y} приписывается d нулей.
 6. Показать, как (и объяснить почему) задачу квадратичного программирования в методе лассо

$$\hat{\boldsymbol{\beta}}^{\text{lasso}} = \underset{\boldsymbol{\beta}}{\operatorname{argmin}} \left\{ \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{j=1}^d x_{ij} \beta_j \right)^2 \right\},$$

при условии

$$\sum_{j=1}^d |\beta_j| \leq s$$

можно свести к задаче квадратичного программирования с $2d + 1$ неизвестными и $2d + 1$ линейными ограничениями.

7. Метод использования линейной регрессии в задаче классификации заключается в следующем. Сопоставим каждому классу k вектор (y_1, y_2, \dots, y_K) , в котором $y_k = 1$, а $y_i = 0$ при $i \neq k$. Собрав вместе индикаторные векторы объектов обучающей выборки, получим матрицу \mathbf{Y} размера $N \times K$. Пусть \mathbf{X} — матрица размера $N \times (d + 1)$, первый столбец которой состоит из единиц, а последующие представляют собой векторы из обучающей выборки. Применяя метод наименьших квадратов одновременно к каждому столбцу матрицы \mathbf{Y} , получаем значения

$$\hat{\mathbf{Y}} = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}.$$

Для каждого столбца \mathbf{y}_k матрицы \mathbf{Y} получим свой столбец коэффициентов $\hat{\boldsymbol{\beta}}_k$. Соберем их в матрицу $\hat{\mathbf{B}}$ размера $(d + 1) \times K$. Имеем

$$\hat{\mathbf{B}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}.$$

Объект x будем классифицировать согласно следующему правилу: Вычислим вектор-строку длины K

$$g(x) = (1, x) \hat{\mathbf{B}}.$$

Отнесем x к классу

$$f(x) = \underset{k}{\operatorname{argmax}} g_k(x).$$

Доказать, что

$$\sum_{k=1}^K g_k(x) = 1.$$

Доказать, что в случае $K = 2$ данный метод эквивалентен решению одной задачи восстановления регрессии. Какой?

3 Дискриминантный анализ

Пример 3. Даны обучающая выборка:

| | | | | | | | | | | |
|-------|---|---|---|---|---|---|---|---|---|---|
| x_1 | 0 | 2 | 1 | 1 | 1 | 2 | 4 | 4 | 4 | 6 |
| x_2 | 4 | 4 | 3 | 5 | 4 | 1 | 0 | 2 | 1 | 1 |
| y | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 1 |

- 1) Изобразить объекты обучающей выборки в пространстве признаков x_1, x_2 ;
- 2) с помощью линейного дискриминантного анализа для каждого класса построить дискриминантные функции и записать уравнение разделяющей поверхности; изобразить поверхность;
- 3) с помощью квадратичного дискриминантного анализа для каждого класса построить дискриминантные функции.

Решение: Оцениваем вероятности классов:

$$\widehat{\Pr}\{Y = 0\} = \frac{1}{2}, \quad \widehat{\Pr}\{Y = 1\} = \frac{1}{2}.$$

Оцениваем средние для классов:

$$\widehat{\mu}_0 = \begin{pmatrix} 1 \\ 4 \end{pmatrix}, \quad \widehat{\mu}_1 = \begin{pmatrix} 4 \\ 1 \end{pmatrix}$$

Выборочные матрицы ковариации для каждого класса:

$$\widehat{\Sigma}_0 = \frac{1}{N_0 - 1} \sum_{y^{(i)}=0} (x^{(i)} - \widehat{\mu}_0)(x^{(i)} - \widehat{\mu}_0)^\top = \frac{1}{4} \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix},$$

$$\widehat{\Sigma}_1 = \frac{1}{N_1 - 1} \sum_{y^{(i)}=1} (x^{(i)} - \widehat{\mu}_1)(x^{(i)} - \widehat{\mu}_1)^\top = \frac{1}{4} \begin{pmatrix} 8 & 0 \\ 0 & 2 \end{pmatrix}.$$

Оцениваем матрицу ковариации:

$$\widehat{\Sigma} = \frac{1}{N - K} \sum_k \sum_{y^{(i)}=k} (x^{(i)} - \widehat{\mu}_k)(x^{(i)} - \widehat{\mu}_k)^\top = \frac{1}{8} \left(\begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix} + \begin{pmatrix} 8 & 0 \\ 0 & 2 \end{pmatrix} \right) = \frac{1}{8} \begin{pmatrix} 10 & 0 \\ 0 & 4 \end{pmatrix} = \begin{pmatrix} 5/4 & 0 \\ 0 & 1/2 \end{pmatrix}.$$

Находим

$$\widehat{\Sigma}_0^{-1} = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}, \quad \widehat{\Sigma}_1^{-1} = \begin{pmatrix} 1/2 & 0 \\ 0 & 2 \end{pmatrix}, \quad \widehat{\Sigma}^{-1} = \begin{pmatrix} 4/5 & 0 \\ 0 & 2 \end{pmatrix}.$$

Линейные дискриминантные функции:

$$\delta_0(x) = x^\top \widehat{\Sigma}^{-1} \widehat{\mu}_0 - \frac{1}{2} \widehat{\mu}_0^\top \widehat{\Sigma}^{-1} \widehat{\mu}_0 + \ln \widehat{\Pr}\{Y = 0\} = \frac{4}{5}x_1 + 8x_2 - \frac{82}{5} - \ln 2,$$

$$\delta_1(x) = x^\top \widehat{\Sigma}^{-1} \widehat{\mu}_1 - \frac{1}{2} \widehat{\mu}_1^\top \widehat{\Sigma}^{-1} \widehat{\mu}_1 + \ln \widehat{\Pr}\{Y = 1\} = \frac{16}{5}x_1 + 2x_2 - \frac{37}{5} - \ln 2.$$

Разделяющая поверхность — прямая с уравнением $\delta_0(x) = \delta_1(x)$ (красная прямая на графике):

$$4x_1 - 10x_2 + 15 = 0.$$


Квадратичные дискриминантные функции:

$$\delta_0(x) = -\frac{1}{2} \ln \det \widehat{\Sigma}_0 - \frac{1}{2} (x - \widehat{\mu}_0)^\top \widehat{\Sigma}_0^{-1} (x - \widehat{\mu}_0) + \ln \widehat{\Pr}\{Y = 0\} = -x_1^2 + 2x_1 - x_2^2 + 8x_2 - 17,$$

$$\delta_1(x) = -\frac{1}{2} \ln \det \widehat{\Sigma}_1 - \frac{1}{2} (x - \widehat{\mu}_1)^\top \widehat{\Sigma}_1^{-1} (x - \widehat{\mu}_1) + \ln \widehat{\Pr}\{Y = 1\} = -\frac{1}{4}x_1^2 + 2x_1 - x_2^2 + 2x_2 - 5 - \ln 2.$$

Разделяющая поверхность — парабола с уравнением (синяя кривая на графике)

$$\frac{3}{4}x_1^2 - 6x_2 + 12 - \ln 2 = 0.$$



Задачи для самостоятельного решения

8.

9. Даны обучающая выборка

| | | | | | | | | |
|-------|----|---|---|---|---|---|---|---|
| x_1 | 0 | 1 | 0 | 2 | 2 | 2 | 4 | 3 |
| x_2 | -1 | 0 | 0 | 0 | 1 | 0 | 1 | 2 |
| y | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 |

1) Методом линейного дискриминантного анализа для каждого класса построить дискриминантную функцию и записать уравнение разделяющей поверхности.

2) Методом квадратичного дискриминантного анализа построить дискриминантные функции.
Изобразить точки и разделяющие поверхности (кривые).

10. Задача Фишера сводится к максимизации отношения Рэлея

$$\max_a \frac{a^\top \mathbf{B} a}{a^\top \mathbf{W} a}.$$


Показать, как эта задача сводится к обобщенной задаче на собственные значения

$$\mathbf{B} a = \lambda \mathbf{W} a.$$

4 Машина опорных векторов

Пример 4. Для данных из предыдущего примера найти уравнение оптимальной разделяющей гиперплоскости, указать опорные точки.

Решение: В качестве двух возможных наборов кандидатур в опорные точки подходят $(1, 3), (2, 1), (4, 2)$ или $(1, 3), (2, 4), (2, 1)$. Среди этих двух наборов нужно выбрать тот, для которого ширина «разделяющего коридора» больше. Для первого набора этот коридор заключен между прямыми (они изображены на рисунке — штриховая малиновая линия) $x_1 - 2x_2 = 0$ и $x_1 - 2x_2 = -5$. Расстояние между прямыми, т. е. ширина коридора, есть $\sqrt{5}$. Для второго набора точек получаем коридор, ограниченный прямыми $x_1 - x_2 = 1$, $x_1 - x_2 = -2$. Его ширина равна $3/\sqrt{2}$. Первый коридор шире, поэтому прямая $2x_1 - 4x_2 = -5$, проходящая через его центр, — оптимальная разделяющая, а точки $(1, 3), (2, 1), (4, 2)$ — опорные.



Задачи для самостоятельного решения

11. Показать, что оптимальная гиперплоскость, разделяющая два множества, является плоскостью, проходящей через середину отрезка, соединяющего пару ближайших точек из выпуклой оболочки каждого из классов, и перпендикулярно ей. Указание: рассмотреть задачу, двойственную к задаче определения оптимальной гиперплоскости.
12. Показать, что в алгоритме *SVM* задача

$$\min_{\beta, \beta_0, \xi_i} \frac{1}{2} \|\beta\|^2 + \gamma \sum_{i=1}^N \xi_i,$$

при ограничениях

$$y_i(x_i^\top \beta + \beta_0) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (i = 1, 2, \dots, N),$$

эквивалентна задаче

$$\min_{\beta, \beta_0} \sum_{i=1}^N [1 - y_i(x_i^\top \beta + \beta_0)]_+ + \alpha \|\beta\|^2,$$

где $[\cdot]_+$ означает положительную часть, и $\alpha = 1/(2\gamma)$.

13. *SVM* и задача восстановления регрессии. Для восстановления β, β_0 в модели $f(x) = x^\top \beta + \beta_0$. рассмотрим задачу минимизации функции

$$H(\beta, \beta_0) = \sum_{i=1}^N V(y_i - f(x_i)) + \frac{\alpha}{2} \|\beta\|^2,$$

где

$$V(t) = V_\varepsilon(t) = \begin{cases} 0, & \text{если } |t| < \varepsilon, \\ |t| - \varepsilon & \text{в противном случае.} \end{cases}$$

Доказать, что решение $\hat{\beta}, \hat{\beta}_0$, минимизирующее функцию $H(\beta, \beta_0)$, можно представить в виде

$$\hat{\beta} = \sum_{i=1}^N (\hat{\alpha}_i^* - \hat{\alpha}_i) x_i, \quad \hat{f}(x) = \sum_{i=1}^N (\hat{\alpha}_i^* - \hat{\alpha}_i) \langle x, x_i \rangle + \beta_0,$$

где $\hat{\alpha}_i$ и $\hat{\alpha}_i^*$ являются решением следующей задачи квадратичного программирования:

$$\min_{\alpha_i, \alpha_i^*} \left(\varepsilon \sum_{i=1}^N (\alpha_i^* + \alpha_i) - \sum_{i=1}^N y_i (\alpha_i^* - \alpha_i) + \frac{1}{2} \sum_{i,j=1}^N (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) \langle x_i, x_j \rangle \right)$$

при ограничениях

$$0 \leq \alpha_i, \alpha_i^* \leq \frac{1}{\lambda}, \quad \sum_{i=1}^N (\alpha_i^* - \alpha_i) = 0, \quad \alpha_i \alpha_i^* = 0.$$

14. Даны обучающая выборка:

| | | | | |
|-------|----|----|----|---|
| x_1 | -1 | -1 | 1 | 1 |
| x_2 | -1 | 1 | -1 | 1 |
| y | 1 | -1 | -1 | 1 |

Подобрать ядро и указать соответствующий SVM-классификатор, для которого ошибка на обучающей выборке равна 0.

5 Наивный байесовский классификатор

Пример 5. Даны обучающая выборка:

| | | | | | | | | | | |
|-------|---|---|---|---|---|---|---|---|---|---|
| x_1 | 1 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 0 |
| x_2 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| y | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 1 |

С помощью наивного байесова классификатора оценить апостериорные вероятности $\Pr(y|x)$, если (a) $x_1 = 1, x_2 = 0$; (b) $x_1 = 0, x_2 = 1$.

Оцениваем априорные вероятности:

$$\widehat{\Pr}\{Y=0\} = \frac{1}{2}, \quad \widehat{\Pr}\{Y=1\} = \frac{1}{2}.$$

Оцениваем условные вероятности:

$$\begin{aligned} \widehat{\Pr}\{X_1=0|Y=0\} &= \frac{3}{5}, & \widehat{\Pr}\{X_1=1|Y=0\} &= \frac{2}{5}, & \widehat{\Pr}\{X_1=0|Y=1\} &= \frac{2}{5}, & \widehat{\Pr}\{X_1=1|Y=1\} &= \frac{3}{5}, \\ \widehat{\Pr}\{X_2=0|Y=0\} &= \frac{1}{5}, & \widehat{\Pr}\{X_2=1|Y=0\} &= \frac{4}{5}, & \widehat{\Pr}\{X_2=0|Y=1\} &= 1, & \widehat{\Pr}\{X_2=1|Y=1\} &= 0. \end{aligned}$$

Используя основное предположение наивного байесова классификатора, получаем

$$\Pr\{Y=0|X_1=1, X_2=0\} = \frac{\Pr\{X_1=1|Y=0\} \Pr\{X_2=0|Y=0\} \Pr\{Y=0\}}{\Pr\{X_1=1, X_2=0\}} \approx \frac{\frac{2}{5} \cdot \frac{1}{5} \cdot \frac{1}{2}}{\frac{1}{25} + \frac{3}{10}} = \frac{\frac{1}{25}}{\frac{17}{50}} = \frac{2}{17},$$

$$\Pr\{Y=1|X_1=1, X_2=0\} = \frac{\Pr\{X_1=1|Y=1\} \Pr\{X_2=0|Y=1\} \Pr\{Y=1\}}{\Pr\{X_1=1, X_2=0\}} \approx \frac{\frac{3}{5} \cdot \frac{1}{5} \cdot \frac{1}{2}}{\frac{1}{25} + \frac{3}{10}} = \frac{\frac{3}{10}}{\frac{17}{50}} = \frac{15}{17}$$

(знаменатели в двух формулах выше равны сумме всех числителей и, следовательно окончательные оценки апостериорных вероятностей получаются после вычисления всех числителей).

$$\Pr\{Y=0|X_1=0, X_2=1\} = \frac{\Pr\{X_1=0|Y=0\} \Pr\{X_2=1|Y=0\} \Pr\{Y=0\}}{\Pr\{X_1=0, X_2=1\}} \approx \frac{\frac{3}{5} \cdot \frac{4}{5} \cdot \frac{1}{2}}{\frac{6}{25} + 0} = \frac{\frac{6}{25}}{\frac{6}{25}} = 1,$$

$$\Pr\{Y=1|X_1=0, X_2=1\} = \frac{\Pr\{X_1=0|Y=1\} \Pr\{X_2=1|Y=1\} \Pr\{Y=1\}}{\Pr\{X_1=0, X_2=1\}} \approx \frac{\frac{2}{5} \cdot 0 \cdot \frac{1}{2}}{\frac{6}{25} + 0} = \frac{0}{\frac{6}{25}} = 0.$$

Задачи для самостоятельного решения

15. Даны обучающая выборка

| | | | | | | | | | | |
|-------|---|---|---|---|---|---|---|---|---|---|
| x_1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 1 | 0 |
| x_2 | 0 | 1 | 0 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |
| y | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 1 |


С помощью наивного байесова классификатора оценить вероятности $\Pr(Y = 0 | X_1 = 1, X_2 = 1)$; $\Pr(Y = 1 | X_1 = 1, X_2 = 1)$.

6 Метод главных компонент

Пример 6. Даны выборка:

| | | | | | | |
|-------|---|----|---|---|---|---|
| x_1 | 4 | -1 | 3 | 3 | 2 | 1 |
| x_2 | 4 | -1 | 0 | 1 | 0 | 2 |

Найти главные направления и объясняемые дисперсии по главным компонентам.



Решение: Имеем

$$\mathbf{X} = \begin{pmatrix} 4 & 4 \\ -1 & -1 \\ 3 & 0 \\ 3 & 1 \\ 2 & 0 \\ 1 & 2 \end{pmatrix},$$

1 шаг. Центрируем данные. Находим $\bar{x} = (2, 1)$. Вычитая компоненты \bar{x} из первого и второго столбца матрицы \mathbf{X} соответственно, получаем

$$\mathbf{X}_c = \begin{pmatrix} 2 & 3 \\ -3 & -2 \\ 1 & -1 \\ 1 & 0 \\ 0 & -1 \\ -1 & 1 \end{pmatrix}.$$

2 шаг. Находим

$$\mathbf{C} = \mathbf{X}_c^\top \mathbf{X}_c = \begin{pmatrix} 16 & 10 \\ 10 & 16 \end{pmatrix}.$$

Матрица

$$\frac{1}{N-1} \mathbf{C} = \begin{pmatrix} 16/5 & 2 \\ 2 & 16/5 \end{pmatrix}.$$

— это выборочная матрица ковариации.

3 шаг. Находим собственные числа и собственные векторы матрицы \mathbf{C} :

$$\det(\mathbf{C} - \lambda \mathbf{I}) = \begin{vmatrix} 16 - \lambda & 10 \\ 10 & 16 - \lambda \end{vmatrix} = \lambda^2 - 32\lambda + 156 = (\lambda - 26)(\lambda - 6).$$

Собственные векторы нормируем:


$$\lambda_1 = 26, \quad v_1 = \frac{\sqrt{2}}{2} \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \quad \lambda_2 = 6, \quad v_2 = \frac{\sqrt{2}}{2} \begin{pmatrix} -1 \\ 1 \end{pmatrix}.$$

Векторы v_1, v_2 — главные компоненты. Значения

$$\frac{1}{N-1}\lambda_1 = \frac{1}{N-1}\sigma_1^2 = \frac{26}{5} = 5.2, \quad \frac{1}{N-1}\lambda_2 = \frac{1}{N-1}\sigma_2^2 = \frac{6}{5} = 1.2$$

— дисперсии по главным компонентам. Находим доли объясненной дисперсии:

$$\frac{\lambda_1}{\lambda_1 + \lambda_2} = 0.8125, \quad \frac{\lambda_2}{\lambda_1 + \lambda_2} = 0.1875.$$



Найдем сингулярное разложение матрицы $\mathbf{X}_c = \mathbf{U}\Sigma\mathbf{V}^\top$:

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \end{pmatrix} = \begin{pmatrix} \sqrt{26} & 0 \\ 0 & \sqrt{6} \end{pmatrix}, \quad \mathbf{V} = (v_1 \mid v_2) = \frac{\sqrt{2}}{2} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix} \approx \begin{pmatrix} 0.7071 & -0.7071 \\ 0.7071 & 0.7071 \end{pmatrix},$$

$$\mathbf{U}\Sigma = \mathbf{X}_c \mathbf{V} = \begin{pmatrix} \frac{5\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ -\frac{5\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ 0 & -\sqrt{2} \\ \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \\ -\frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \\ 0 & \sqrt{2} \end{pmatrix} \approx \begin{pmatrix} 3.5355 & 0.7071 \\ -3.5355 & 0.7071 \\ 0 & -1.4142 \\ 0.7071 & -0.7071 \\ -0.7071 & -0.7071 \\ 0 & 1.4142 \end{pmatrix},$$

$$\mathbf{U} = \mathbf{X}_c \mathbf{V} \Sigma^{-1} = \begin{pmatrix} \frac{5\sqrt{13}}{26} & \frac{\sqrt{3}}{6} \\ -\frac{5\sqrt{13}}{26} & \frac{\sqrt{3}}{6} \\ 0 & -\frac{\sqrt{3}}{3} \\ \frac{\sqrt{13}}{26} & -\frac{\sqrt{3}}{6} \\ -\frac{\sqrt{13}}{26} & -\frac{\sqrt{3}}{6} \\ 0 & \frac{\sqrt{3}}{3} \end{pmatrix} \approx \begin{pmatrix} 0.6934 & 0.2887 \\ -0.6934 & 0.2887 \\ 0 & -0.5774 \\ 0.1387 & -0.2887 \\ -0.1387 & -0.2887 \\ 0 & 0.5774 \end{pmatrix}.$$

Напомним, что

- в матрице *нагрузок* (loadings) \mathbf{V} по столбцам записаны координаты векторов главных компонент v_1, v_2 ;
- в матрице *счетов*, или *результатов*, (scores) $\mathbf{U}\Sigma$ по строкам — координаты проекций точек на главные компоненты;
- в матрице *Z-счетов*, или *Z-результатов*, (z-scores) $\mathbf{U}\sqrt{N}$ по строкам — координаты проекций точек на главные компоненты, нормированные на единичные выборочные дисперсии (whitening).

Задачи для самостоятельного решения

16. Даны выборка:

| | | | | |
|-------|---|---|----|----|
| x_1 | 4 | 0 | -2 | 2 |
| x_2 | 3 | 1 | -3 | -1 |

Найти главные направления и дисперсии по главным компонентам. Изобразить точки и главные направления.

17. Даны выборка:

| | | | | | |
|-------|---|----|----|---|----|
| x_1 | 4 | 0 | -1 | 3 | 4 |
| x_2 | 2 | -3 | -2 | 1 | 2 |
| x_3 | 3 | 2 | 2 | 1 | -3 |

Найти главные направления и дисперсии по главным компонентам.

7 Логистическая регрессия. Нейронные сети

18. Пусть $\sigma(z) = \frac{1}{1 + e^{-z}}$ (сигмоидальная функция). Проверить, что $\sigma' = \sigma(1 - \sigma)$.

19. Пусть в задаче классификации на K классов $\{1, 2, \dots, K\}$ последний слой нейронной сети вычисляет softmax-функцию:

$$g_k(s_1, s_2, \dots, s_K) = e^{s_k} \left/ \sum_{\ell=1}^K e^{s_\ell} \right..$$

В качестве штрафа используется кросс-энтропия (logloss-функция):

$$R^{(i)} = - \sum_{k=1}^K I(y^{(i)} = k) \ln g_k(s_1, s_2, \dots, s_K),$$

где $g_k(s_1, s_2, \dots, s_K)$ — softmax-функция. Доказать, что

- 1) $\frac{\partial g_k}{\partial s_\ell} = g_k \cdot (I(k = \ell) - g_\ell)$;
- 2) $\frac{\partial R^{(i)}}{\partial g_k} = -\frac{I(y^{(i)})}{g_k}$;
- 3) $\frac{\partial R^{(i)}}{\partial s_\ell} = g_\ell - I(\ell = y^{(i)})$.

20. Предположим, что рассматривается K задач двуклассовой классификации, в каждой из которых по $x \in \mathcal{X}$ требуется предсказать $y_k \in \{0, 1\}$ ($k = 1, 2, \dots, K$) (например, требуется определить, присутствует или отсутствует на изображении x объект k). Обучающая выборка составлена из пар $(x^{(i)}, y^{(i)})$, где $y^{(i)} = (y_1^{(i)}, y_2^{(i)}, \dots, y_K^{(i)}) \in \{0, 1\}^K$ ($i = 1, 2, \dots, N$). Для решения такой задачи можно использовать нейронную сеть, последний слой которой вычисляет K сигмоидальных функций

$$g_k(s_k) = \frac{1}{1 + e^{-s_k}} \quad (k = 1, 2, \dots, K).$$

Пусть в качестве штрафа используется

$$R^{(i)} = - \sum_{k=1}^K \left(y_k^{(i)} \ln g_k + (1 - y_k^{(i)}) \ln(1 - g_k) \right).$$

Доказать, что

$$\frac{\partial R^{(i)}}{\partial s_k} = g_k - y_k^{(i)}.$$

21. Нейронная сеть с двумя нелинейными слоями вычисляет функцию $\text{softmax}(B(\sigma(Ax)))$. Пусть в качестве функции потерь используется logloss. Таким образом, на объекте $x^{(i)}$ потери равны $\text{logloss}(\text{softmax}(B(\sigma(Ax^{(i)})))$. Пользуясь результатом задачи № 1, выпишите матричные формулы для алгоритма backpropagation.

8 Деревья решений

22. В дереве решений (для некоторой задачи классификации с K классами) рассмотрим вершину m и соответствующий ящик R_m . Обозначим p_{mk} долю объектов класса k в этом ящике ($k = 1, 2, \dots, K$). Рассмотрим классификатор, который для объектов, попавших в ящик R_m выбирает класс случайно, причем класс k выбирается с вероятностью, равной p_{mk} . Доказать, что математическое ожидание частоты ошибок этого классификатора на объектах обучающей выборки, попавших в R_m , равно индексу Джини.
23. Пусть при построении дерева решений в задаче классификации с двумя классами в текущую вершину попало 400 объектов из первого класса и столько же из второго. Пусть необходимо сделать выбор между разбиением на две ветви (300, 100) и (100, 300) и разбиением на две ветви (200, 400), (200, 0). Какое из этих разбиений кажется предпочтительнее (объясните)? Какое разбиение выберет критерий на основе минимизации ошибки, энтропийный критерий и критерий Джини? Приведите свой пример, когда все три критерия дают разные разбиения.
24. Пусть из обучающей выборки длины N объектов генерируется бутстрэп-выборка (выборка с возвращением) той же длины. Найти математическое ожидание доли объектов, не вошедших в бутстрэп-выборку. Чему равен предел этого математического ожидания при $n \rightarrow \infty$. Какой вывод отсюда можно сделать относительно out-of-bag метода оценки качества ансамбля классификаторов?

9 Теория Вапника–Червоненкиса

25. Пусть Z_1, Z_2, \dots, Z_N — независимые одинаково распределенные случайные величины.

$$\Pr(Z_i = 1) = \theta, \quad \Pr(Z_i = 0) = 1 - \theta$$

(схема Бернулли). Доказать, что

$$\Pr(|\hat{\theta} - \theta| > \gamma) \leq 2e^{-2\gamma^2 N},$$

где

$$\hat{\theta} = \frac{1}{N} \sum_{i=1}^N Z_i.$$

26. Доказать, что если \mathcal{F} конечно, то $\text{VC } \mathcal{F} \leq \log_2 |\mathcal{F}|$. Для каждого d построить пример \mathcal{F} , на котором эта оценка достигается.
27. Доказать, что при $h \leq N$
- $$\binom{N}{0} + \binom{N}{1} + \dots + \binom{N}{h} < \left(\frac{eN}{h}\right)^h.$$
28. Пусть \mathcal{X} — подмножество в \mathbf{R}^d , а \mathcal{F} — некоторое множество функций, отображающих \mathcal{X} в $\{0, 1\}$. Введем класс $\mathcal{F}' = \{f \vee g : f, g \in \mathcal{F}\}$, состоящий из дизъюнкций каждой пары функций в \mathcal{F} . Доказать, что для функции роста класса \mathcal{F}' справедливо неравенство $\Delta(\mathcal{F}', N) \leq \Delta(\mathcal{F}, N)^2$. Воспользовавшись леммой Зауэра, доказать, что $\text{VC } \mathcal{F}' \leq 10 \text{VC } \mathcal{F}$. Что изменится, если вместо лизъинций рассмотреть (а) все конъюнкции, (б) суммы по модулю 2?
29. Функцию $f : \mathbf{R}^d \rightarrow \{0, 1\}$ назовем *ящиком*, если существуют вещественные числа $a_1, a_2, \dots, a_d, b_1, b_2, \dots, b_d$, такие, что $f(x) = 1$ тогда и только тогда, когда $a_i \leq x \leq b_i$ ($i = 1, 2, \dots, d$). Найти функцию роста и размерность Вапника–Червоненкиса для класса всех ящиков. Проиллюстрировать на этом примере лемму Зауэра.
30. Пусть T_h — множество всех функций $f : \mathbf{R}^d \rightarrow \{0, 1\}$, вычисляемых бинарными деревьями решений, высоты не выше h . Найти функцию роста и размерность Вапника–Червоненкиса для класса T_h . Проиллюстрировать на этом примере лемму Зауэра.

31. Пусть H_d — множество всех булевых функций $f : \{0, 1\}^d \rightarrow \{0, 1\}$, представимых ДНФ, в которых каждая элементарная конъюнкция представляет собой одиночный символ, обозначающий переменную (без отрицания). Найти функцию роста и размерность Вапника–Червоненкиса для класса H_d . Проиллюстрировать на этом примере лемму Зауэра.
32. Функцию $f : \mathbf{R}^2 \rightarrow \{0, 1\}$ назовем полигоном (точнее: k -вершинным полигоном), если найдется выпуклый k -угольник M , такой, что $f(x) = 1$ тогда и только тогда, когда x принадлежит M . Пусть P — множество всех полигонов, а P_k — множество всех k -вершинных полигонов. Найти $\text{VC } P$ и $\text{VC } P_k$.
33. Привести пример бесконечного класса \mathcal{F} , для которого $\text{VC } \mathcal{F} = 1$.
34. Размерность Вапника–Червоненкиса для задачи восстановления регрессии. Пусть \mathcal{F} — некоторый класс функций $f : \mathcal{X} \rightarrow \mathcal{Y}$. Размерностью Вапника–Червоненкиса для класса \mathcal{F} называется $\text{VC } \mathcal{F}'$, где

$$\mathcal{F}' = \{I(f(x) - y) : f \in \mathcal{F}, y \in \mathcal{Y}\}.$$

Найти размерность Вапника–Червоненкиса для класса $\{\sin \alpha x : \alpha \in \mathbf{R}\}$.

10 Еще задачи

35. Рассмотрим задачу восстановления регрессии с квадратичной функцией потерь $L(y', y) = (y' - y)^2$. Доказать, что если $f^*(x) = \underset{c}{\operatorname{argmin}} \mathbf{E}((Y - c)^2 | X = x)$, то $f^*(x) = \mathbf{E}(Y | X = x)$ (регрессионная функция). Чему тогда равен средний риск $R(f^*)$?
36. Рассмотрим задачу восстановления регрессии с функцией потерь $L(y', y) = |y' - y|$. Доказать, что минимум среднему риску доставляет при этом условная медиана $f(x) = \text{median}(Y | X = x)$.
37. А как должна выглядеть функция потерь, чтобы минимум среднему риску давала условная мода?
38. Пусть в задаче классификации с двумя классами $\{0, 1\}$ используется функция потерь $L(y', y)$, такая, что $L(0, 0) = L(1, 1) = 0$, $L(1, 0) = \ell_1$, $L(0, 1) = \ell_0$. Докажите, что в этом случае байесов классификатор $f^*(x)$ удовлетворяет условию
- $$f(x) = \underset{y \in \{0, 1\}}{\operatorname{argmax}} \ell_y \Pr(y | x).$$
39. Выразить байесов классификатор $f^*(x)$ для задачи классификации с K классами, если функция потерь равна $L(y', y) = \ell_{y'y}$ ($y', y = 1, 2, \dots, K$).
40. Пусть рассматривается задача бинарной классификации. Доказать, что если известно сколько в выборке представителей каждого из двух классов, то по любым двум показателям из списка TPR, TNR, PPV, NPV определяются остальные два.
41. Пусть рассматривается задача бинарной классификации. Верно ли, что
- 1) если у двух классификаторов на одной и той же выборке совпадают PPV (Precision) и совпадают TPR (Recall, или Sensitivity), то будут совпадать TNR (Specificity) и NPV;
 - 2) если у двух классификаторов на одной и той же выборке совпадают TNR (Specificity) и совпадают NPV, то будут совпадать PPV (Precision) и TPR (Recall или Sensitivity);
 - 3) совпадение ROC кривых (для двух классификаторов на одной и той же выборке) влечет совпадение Precision-Recall кривых и наоборот?
42. Пусть в задаче классификации на 2 класса $\{0, 1\}$ некоторый классификатор (например, наивный байесовский) определяет следующие оценки $g(x)$ апостериорной вероятности принадлежности объекта x к классу 1:

| i | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|--------------|------|------|------|------|------|------|------|------|------|
| $y^{(i)}$ | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 |
| $g(x^{(i)})$ | 0.75 | 0.15 | 0.11 | 0.23 | 0.09 | 0.10 | 0.66 | 0.82 | 0.50 |

Постройте ROC-кривую. Вычислите AUC. Для классификатора $f(x) = I(g(x) \geq 0.5)$ выпишите матрицу рассогласования и найдите FPR, FNR, TNR, TPR, PPV, accuracy, error, F1.

43. Видоизмените алгоритм, разобранный на лекции для построения ROC-кривой, так, чтобы он находил ROC AUC.
44. Пусть N точек распределены случайно равномерно в единичной d -мерной гиперсфере. Доказать, что медианное расстояние от центра сферы до ближайшей точки равно

$$\rho(d, N) = \sqrt[d]{1 - \sqrt[N]{1/2}}.$$

Найти предел $\rho(d, N)$ при $d \rightarrow \infty$, $N = O(d)$. Какой вывод из этого можно сделать применительно к методу ближайшего соседа при больших d ?

45. *Bias-variance trade-off.* Рассмотрим задачу восстановления зависимости $Y = f^*(X)$, где X — случайная величина, а f^* — неизвестная *детерминированная* функция. Пусть $x^{(1)}, x^{(2)}, \dots, x^{(N)}$ суть независимые реализации величины X . В качестве модельной зависимости возьмем функцию $f(x, D)$, где $D = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$. Разложить $E_D(f(x, D) - f^*(x))^2$ в сумму квадрата математического ожидания смещения (bias) и дисперсии (variance).

46. *Может ли использование коррелированных переменных улучшить качество предсказания?* Рассмотрим задачу классификации с двумя классами. Пусть пространство признаков двумерное. Объекты каждого класса имеют нормальное распределение с математическим ожиданием $(-1, -1)$ и $(1, 1)$ соответственно и единичной матрицей ковариации каждый. Априорные вероятности классов равны $\frac{1}{2}$.

- 1) Вычислить коэффициент корреляции для переменных x_1, x_2 .
- 2) Найти байесов классификатор и вычислить байесову ошибку для усеченной задачи, рассматривая только одну переменную x_1 .
- 3) Найти байесов классификатор и вычислить байесову ошибку для исходной задачи.
- 4) Приводит ли использование второй переменной к уменьшению ошибки?

47. Рассмотрим задачу классификации с двумя классами 0 и 1. Пусть пространство признаков двумерное. Объекты каждого класса имеют нормальное распределение с математическим ожиданием $(0, 0)$ и $(1, 1)$ соответственно и матрицей ковариации

$$\Sigma = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}.$$

Априорные вероятности классов равны $\Pr\{Y = 0\} = \frac{1}{3}$ и $\Pr\{Y = 1\} = \frac{2}{3}$.

- 1) Найти уравнение разделяющей поверхности байесова классификатора.
- 2) Найти собственное разложение матрицы Σ .
- 3) Перейти к новым координатам, оси которых совпадают с собственными векторами матрицы Σ .
- 4) Выписать уравнение разделяющей поверхности байесова классификатора в новых координатах.

48. *Влияние шума на качество предсказания.* Пусть пространство признаков одномерное и обучающая выборка состоит из двух объектов $x^{(0)} = 0, x^{(1)} = 1$. Добавим к объектам шумовой признак, распределенный равномерно на отрезке $[-1, 1]$. Какова вероятность, что объект $x = (0.32, 0)$ окажется ближе (по евклидову расстоянию) к объекту $x^{(1)}$, чем к $x^{(0)}$? (Шум к x не добавляется. Только к $x^{(0)} = 0$ и $x^{(1)} = 1$.)

49. Выпуклым полиэдром (или выпуклым многогранником) в пространстве \mathbf{R}^d называется пересечение конечного числа полупространств, т. е. множество решений некоторой системы линейных неравенств:

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1d}x_d \leq b_1, \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2d}x_d \leq b_2, \\ \dots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{md}x_d \leq b_m, \end{cases}$$

Доказать, что область, в которой все точки имеют одинаковых k ближайших соседей (для евклидова расстояния) есть полиэдр.