

# Задачи по машинному обучению

составитель: **Н. Ю. Золотых**

Нижний Новгород  
2013, 2017

## Содержание

1	Метод наименьших квадратов	2
2	Дискриминантный анализ	4
3	Машина опорных векторов	6
4	Наивный байесовский классификатор	7
5	Метод главных компонент	8
6	Теория Вапника–Червоненкиса	11
7	Еще задачи	12

## 1. Метод наименьших квадратов

**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

1. Дана 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  $\mathbf{X}^\top \mathbf{X} \beta = \mathbf{X}^\top \mathbf{y}$  и решить ее. Регуляризованная система:  $(\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I}) \beta = \mathbf{X}^\top \mathbf{y}$ , где  $\mathbf{I}$  — единичная матрица.

2. Рассмотрим задачу восстановления регрессии с квадратичной функцией потерь  $L(y', y) = (y' - y)^2$ . Доказать, что если  $f^*(x) = \underset{c}{\operatorname{argmin}} \mathbb{E}((Y - c)^2 | X = x)$ , то  $f^*(x) = \mathbb{E}(Y | X = x)$  (регрессионная функция). Чему тогда равен средний риск  $R(f^*)$ ?
3. Рассмотрим задачу восстановления регрессии с функцией потерь  $L(y', y) = |y' - y|$ . Доказать, что минимум среднему риску доставляет при этом условная медиана  $f(x) = \operatorname{median}(Y | X = x)$ .
4. Рассмотрим задачу восстановления регрессии, в которой  $\mathbf{y}$  распределен согласно нормальному закону  $N(\mathbf{X}, \sigma^2 \mathbf{I})$ , а  $\beta$  имеет априорное распределение  $N(0, \tau \mathbf{I})$ . Найти апостериорное распределение для  $\beta$ . Доказать, что  $\beta^{\operatorname{ridge}}$  есть его математическое ожидание. Найти связь между параметром регуляризации  $\lambda$  и дисперсиями  $\tau, \sigma^2$ .
5. Показать, что процедура гребневой регрессии эквивалентна обычному методу наименьших квадратов, примененному к расширенным данным: к централизованной матрице  $\mathbf{X}$  дописывается матрица  $\sqrt{\lambda} \mathbf{I}$ , к вектору  $\mathbf{y}$  приписывается  $p$  нулей.
6. Показать, как (и объяснить почему) задачу квадратичного программирования в методе

лассо

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

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  $\hat{\beta}_k$ . 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?

## 2. Дискриминантный анализ

**Пример 3.** Дана 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:

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

Выборочные матрицы ковариации для каждого класса:

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

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

Оцениваем матрицу ковариации:

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

Находим

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

Линейные дискриминантные функции:

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

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

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

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


Квадратичные дискриминантные функции:

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

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

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

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



### Задачи

8. Дана 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).

9. Задача Фишера сводится к максимизации отношения Рэля

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


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

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

### 3. Машина опорных векторов

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

*Решение:* В качестве двух возможных наборов кандидатов 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

10. 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 ему. Указание: рассмотреть задачу, двойственную к задаче определения оптимальной гиперплоскости.

11. 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

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

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

12. SVM и задача восстановления регрессии. Для восстановления  $\beta, \beta_0$  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

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

13. Дана 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.

## 4. Наивный байесовский классификатор

Пример 5. Дана 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 (а)  $x_1 = 1, x_2 = 0$ ; (б)  $x_1 = 0, x_2 = 1$ .

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

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

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

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

## Задачи

14. Дана 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  $\Pr(Y = 0|X_1 = 1, X_2 = 1)$ ;  $\Pr(Y = 1|X_1 = 1, X_2 = 1)$ .

## 5. Метод главных компонент

Пример 6. Дана выборка:

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

Найти главные направления и объясненные 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  $\mathbf{X}_c = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$ :

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

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

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

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)  $\mathbf{U}\mathbf{\Sigma}$  по строкам — координаты проекций точек на главные компоненты;
- в матрице *Z-счетов*, или *Z-результатов*, (z-scores)  $\mathbf{U}$  по строкам — координаты проекций точек на главные компоненты, нормированные на единичные выборочные дисперсии.

### Задачи

15. Дана 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.

16. Дана 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.

## 6. Теория Вапника–Червоненкиса

17. 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

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

18. 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.

19. Доказать, что при  $h \leq N$

$$\binom{N}{0} + \binom{N}{1} + \dots + \binom{N}{h} < \left(\frac{eN}{h}\right)^h.$$

20. 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 лизъюнкций рассмотреть (а) все конъюнкции, (б) суммы по модулю 2?

21. 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.

22. 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.

23. 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.

24. 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  $\text{VC } P_k$ .

25. Привести пример бесконечного класса  $\mathcal{F}$ , для которого  $\text{VC } \mathcal{F} = 1$ .

26. *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  $\{\sin \alpha x : \alpha \in \mathbf{R}\}$ .



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.

34. 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.