

Дифференцирование по вектору и матрице

Задача 1. $\frac{\partial}{\partial \mathbf{x}} \mathbf{x}^T \mathbf{a} = \mathbf{a}$.

$$\frac{\partial}{\partial x_p} \mathbf{x}^T \mathbf{a} = \frac{\partial}{\partial x_p} \sum_{i=1}^n x_i a_i = a_p.$$

Задача 2. $\frac{\partial}{\partial \mathbf{x}} \mathbf{x}^T A \mathbf{x} = (A + A^T) \mathbf{x}$.

$$\frac{\partial}{\partial x_p} \mathbf{x}^T A \mathbf{x} = \frac{\partial}{\partial x_p} \sum_{i,j=1}^n a_{ij} x_i x_j = 2a_{pp} x_p + \sum_{j \neq p} a_{pj} x_j + \sum_{i \neq p} a_{ip} x_i = \sum_{j=1}^n a_{pj} x_j + \sum_{i=1}^n a_{ip} x_i = (A \mathbf{x})_p + (A^T \mathbf{x})_p.$$

Задача 3. $\frac{\partial}{\partial \mathbf{x}} \|\mathbf{Ax} - \mathbf{b}\|_2^2 = 2A^T(\mathbf{Ax} - \mathbf{b})$.

$$\begin{aligned} \frac{\partial}{\partial \mathbf{x}} \|\mathbf{Ax} - \mathbf{b}\|_2^2 &= \frac{\partial}{\partial \mathbf{x}} (\mathbf{Ax} - \mathbf{b})^T (\mathbf{Ax} - \mathbf{b}) = \frac{\partial}{\partial \mathbf{x}} \left(\mathbf{x}^T A^T A \mathbf{x} - \mathbf{x}^T A^T \mathbf{b} - \underbrace{\mathbf{b}^T A \mathbf{x}}_{=\mathbf{x}^T A^T \mathbf{b}} + \mathbf{b}^T \mathbf{b} \right) = \\ &= \{ \text{используем результаты задач 1 и 2} \} = 2A^T A \mathbf{x} - 2A^T \mathbf{b} = 2A^T (\mathbf{Ax} - \mathbf{b}). \end{aligned}$$

Задача 4. $\frac{\partial}{\partial A} \det A = (\det A) A^T$.

$$\begin{aligned} \frac{\partial}{\partial a_{ij}} \det A &= \{ \text{разложим определитель по } i\text{-ой строке} \} = \frac{\partial}{\partial a_{ij}} \sum_{k=1}^n a_{ik} M_{ik} = \\ &= \{ M_{ik} - \text{алгебраическое дополнение к элементу } a_{ik}, \text{ оно не зависит от } a_{ij} \forall k \} = M_{ij} = (\det A) (A^{-1})_{ji}. \end{aligned}$$

Задача 5. $\frac{\partial}{\partial A} \text{tr}(AB) = B^T$.

$$\frac{\partial}{\partial a_{pq}} \text{tr}(AB) = \frac{\partial}{\partial a_{pq}} \sum_{i,j=1}^n a_{ij} b_{ji} = b_{qp}.$$

Задача 6. $\frac{\partial}{\partial A} \mathbf{x}^T A \mathbf{y} = \mathbf{xy}^T$.

$$\begin{aligned} \frac{\partial}{\partial A} \mathbf{x}^T A \mathbf{y} &= \frac{\partial}{\partial A} \text{tr}(\mathbf{x}^T A \mathbf{y}) = \{ \text{используем свойство } \text{tr}(ABC) = \text{tr}(BCA) = \text{tr}(CAB) \} = \\ &= \frac{\partial}{\partial A} \text{tr}(A \mathbf{y} \mathbf{x}^T) = \{ \text{используем результат задачи 5} \} = (\mathbf{y} \mathbf{x}^T)^T = \mathbf{xy}^T. \end{aligned}$$

Задача 7. $\frac{\partial}{\partial x} \log \det A = \text{tr} \left(\frac{\partial A}{\partial x} A^{-1} \right)$. Здесь $x \in \mathbb{R}$, каждый элемент A зависит от x .

$$\begin{aligned} \frac{\partial}{\partial x} \log \det A &= \frac{1}{\det A} \frac{\partial \det A}{\partial x} = \left\{ \text{производная сложной функции, зависящей от матрицы} \right. \\ &\quad \left. \frac{\partial}{\partial x} f(a_{11}(x), a_{12}(x), \dots, a_{nm}(x)) = \sum_{i,j=1}^{n,m} \frac{\partial f}{\partial a_{ij}} \frac{\partial a_{ij}}{\partial x} \right\} = \frac{1}{\det A} \sum_{i,j=1}^{n,m} \frac{\partial \det A}{\partial a_{ij}} \frac{\partial a_{ij}}{\partial x} = \\ &= \{ \text{используем результат задачи 4} \} = \frac{1}{\det A} \sum_{i,j=1}^{n,m} \det A (A^{-T})_{ij} \left(\frac{\partial A}{\partial x} \right)_{ij} = \sum_{i,j=1}^{n,m} \left(\frac{\partial A}{\partial x} \right)_{ij} (A^{-1})_{ji} = \text{tr} \left(\frac{\partial A}{\partial x} A^{-1} \right). \end{aligned}$$

Задача 8. $\frac{\partial}{\partial x} A^{-1} = -A^{-1} \frac{\partial A}{\partial x} A^{-1}$. Здесь $x \in \mathbb{R}$, каждый элемент A зависит от x .

По определению обратной матрицы

$$A^{-1}A = I.$$

Дифференцируя обе части равенства по x , получаем:

$$\frac{\partial I}{\partial x} = 0 = \frac{\partial}{\partial x}(A^{-1}A) = \frac{\partial A^{-1}}{\partial x}A + A^{-1}\frac{\partial A}{\partial x}.$$

Выражая из последнего равенства $\frac{\partial A^{-1}}{\partial x}$, получаем требуемый результат.

Задача 9. $\frac{\partial}{\partial A} \text{tr}(A^{-1}B) = -(A^{-1}BA^{-1})^T$.

$$\begin{aligned} \frac{\partial}{\partial a_{pq}} \text{tr}(A^{-1}B) &= \text{tr}\left(\frac{\partial A^{-1}B}{\partial a_{pq}}\right) = \text{tr}\left(\frac{\partial A^{-1}}{\partial a_{pq}}B\right) = \{\text{используем результат задачи 8}\} = \text{tr}\left(-A^{-1}\frac{\partial A}{\partial a_{pq}}A^{-1}B\right) = \\ &= \{\text{обозначим через } I_{pq} \text{ матрицу, в которой в позиции } pq \text{ стоит } 1, \text{ а в остальных нули}\} = \\ &= -\text{tr}(A^{-1}BA^{-1}I_{pq}) = -\sum_{i,j=1}^n (A^{-1}BA^{-1})_{ij}(I_{pq})_{ji} = -(A^{-1}BA^{-1})_{qp}. \end{aligned}$$

Нормальное распределение

По определению плотность нормального распределения выглядит как

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \Sigma) = \frac{1}{\sqrt{2\pi}^D \sqrt{\det \Sigma}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})\right).$$

Здесь

$$\begin{aligned} \mathbb{E}\mathbf{x} &= \boldsymbol{\mu}, \\ \mathbb{E}(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T &= \Sigma. \end{aligned}$$

Задача 10. $\mathbb{E}\mathbf{x}^T \mathbf{x} = \text{tr} \Sigma + \boldsymbol{\mu}^T \boldsymbol{\mu}$.

$$\begin{aligned} \Sigma &= \mathbb{E}(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T = \mathbb{E}(\mathbf{x}\mathbf{x}^T - \mathbf{x}\boldsymbol{\mu}^T - \boldsymbol{\mu}\mathbf{x}^T + \boldsymbol{\mu}\boldsymbol{\mu}^T) = \\ &= \mathbb{E}\mathbf{x}\mathbf{x}^T - \underbrace{\mathbb{E}\mathbf{x}\boldsymbol{\mu}^T}_{=\boldsymbol{\mu}} - \mathbb{E}\boldsymbol{\mu}\mathbf{x}^T + \boldsymbol{\mu}\boldsymbol{\mu}^T = \mathbb{E}\mathbf{x}\mathbf{x}^T - \boldsymbol{\mu}\boldsymbol{\mu}^T - \boldsymbol{\mu}\boldsymbol{\mu}^T + \boldsymbol{\mu}\boldsymbol{\mu}^T = \mathbb{E}\mathbf{x}\mathbf{x}^T - \boldsymbol{\mu}\boldsymbol{\mu}^T. \end{aligned}$$

$$\mathbb{E}\mathbf{x}^T \mathbf{x} = \mathbb{E} \text{tr}(\mathbf{x}^T \mathbf{x}) = \mathbb{E} \text{tr}(\mathbf{x}\mathbf{x}^T) = \text{tr} \mathbb{E}\mathbf{x}\mathbf{x}^T = \text{tr}(\Sigma + \boldsymbol{\mu}\boldsymbol{\mu}^T) = \text{tr} \Sigma + \text{tr}(\boldsymbol{\mu}^T \boldsymbol{\mu}) = \text{tr} \Sigma + \boldsymbol{\mu}^T \boldsymbol{\mu}.$$

Задача 11. Пусть имеется независимая выборка $\mathbf{x}_1, \dots, \mathbf{x}_N$ из $\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \Sigma)$. Требуется найти оценки максимального правдоподобия для параметров $\boldsymbol{\mu}, \Sigma$.

Функция правдоподобия:

$$\begin{aligned} p(X|\boldsymbol{\mu}, \Sigma) &= \prod_{n=1}^N p(\mathbf{x}_n|\boldsymbol{\mu}, \Sigma) = \prod_{n=1}^N \mathcal{N}(\mathbf{x}_n|\boldsymbol{\mu}, \Sigma) = \prod_{n=1}^N \frac{1}{\sqrt{2\pi}^D \sqrt{\det \Sigma}} \exp\left(-\frac{1}{2}(\mathbf{x}_n - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}_n - \boldsymbol{\mu})\right) = \\ &= \left(\frac{1}{\sqrt{2\pi}^D \sqrt{\det \Sigma}}\right)^N \exp\left(-\frac{1}{2} \sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}_n - \boldsymbol{\mu})\right). \end{aligned}$$

$$\log p(X|\boldsymbol{\mu}, \Sigma) = -\frac{ND}{2} \log(2\pi) - \frac{N}{2} \log \det \Sigma - \frac{1}{2} \sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}_n - \boldsymbol{\mu}).$$

Дифференцируя $\log p(X|\boldsymbol{\mu}, \Sigma)$ по $\boldsymbol{\mu}$, получаем:

$$\begin{aligned} \frac{\partial}{\partial \boldsymbol{\mu}} \log p(X|\boldsymbol{\mu}, \Sigma) &= -\frac{1}{2} \sum_{n=1}^N \frac{\partial}{\partial \boldsymbol{\mu}} (\mathbf{x}_n^T \Sigma^{-1} \mathbf{x}_n - 2\boldsymbol{\mu}^T \Sigma^{-1} \mathbf{x}_n + \boldsymbol{\mu}^T \Sigma^{-1} \boldsymbol{\mu}) = \\ &= -\frac{1}{2} \sum_{n=1}^N (-2\Sigma^{-1} \mathbf{x}_n + 2\Sigma^{-1} \boldsymbol{\mu}) = \Sigma^{-1} \left(\sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu}) \right) = 0. \end{aligned}$$

Домножая в последнем равенстве на невырожденную матрицу Σ , получаем

$$\sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu}) = 0 \Rightarrow \boldsymbol{\mu}_{ML} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n.$$

Теперь дифференцируем $\log p(X|\boldsymbol{\mu}, \Sigma)$ по Σ :

$$\begin{aligned} \frac{\partial}{\partial \Sigma} \log p(X|\boldsymbol{\mu}, \Sigma) &= -\frac{N}{2} \frac{\partial}{\partial \Sigma} \log \det \Sigma - \frac{1}{2} \frac{\partial}{\partial \Sigma} \sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x}_n - \boldsymbol{\mu}) = \\ &= -\frac{N}{2} \frac{1}{\det \Sigma} \frac{\partial \det \Sigma}{\partial \Sigma} - \frac{1}{2} \frac{\partial}{\partial \Sigma} \operatorname{tr} \left(\sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu}) \Sigma^{-1} (\mathbf{x}_n - \boldsymbol{\mu}) \right) = \{ \text{используем результат задачи 4} \} = \\ &= -\frac{N}{2} \Sigma^{-T} - \frac{1}{2} \frac{\partial}{\partial \Sigma} \operatorname{tr} \left(\underbrace{\Sigma^{-1} \sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu}) (\mathbf{x}_n - \boldsymbol{\mu})^T}_{\text{обозначим через } S} \right) = \{ \text{используем результат задачи 9} \} = -\frac{N}{2} \Sigma^{-T} + \frac{1}{2} \Sigma^{-T} S^T \Sigma^{-T} = 0. \end{aligned}$$

Домножая в последнем равенстве слева и справа на Σ^T , получаем:

$$-\frac{N}{2} \Sigma^T + \frac{1}{2} S^T = 0 \Rightarrow \Sigma_{ML} = \frac{1}{N} S.$$

Заметим, что при взятии производной $\log p(X|\boldsymbol{\mu}, \Sigma)$ по Σ нигде не использовалось свойство симметричности Σ . Этого оказалось достаточно, т.к. итоговый ответ $\frac{1}{N} S$ получился симметричной матрицей. Если бы это оказалось не так, то тогда пришлось бы вычислять производную с дополнительным учётом свойства симметричности. Тогда, в частности, при решении задачи 9 при вычислении $\frac{\partial A}{\partial a_{pq}}$ возникла бы матрица с единицей в позициях pq и qp .

Задача 12. Рассмотрим многомерное нормальное распределение $\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \Sigma)$ и разобьём вектор \mathbf{x} на два подвектора \mathbf{x}_a и \mathbf{x}_b . Тогда

$$\mathbf{x} = \begin{bmatrix} \mathbf{x}_a \\ \mathbf{x}_b \end{bmatrix}, \quad \boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_a \\ \boldsymbol{\mu}_b \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \Sigma_{aa} & \Sigma_{ab} \\ \Sigma_{ab}^T & \Sigma_{bb} \end{bmatrix}, \quad \Lambda := \Sigma^{-1} = \begin{bmatrix} \Lambda_{aa} & \Lambda_{ab} \\ \Lambda_{ab}^T & \Lambda_{bb} \end{bmatrix}.$$

Требуется найти распределение $p(\mathbf{x}_a|\mathbf{x}_b)$.

$$\begin{aligned} p(\mathbf{x}_a|\mathbf{x}_b) &\propto p(\mathbf{x}_a, \mathbf{x}_b) = \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \Sigma) \propto \\ &\propto \exp \left[-\frac{1}{2} \left((\mathbf{x}_a - \boldsymbol{\mu}_a)^T \Lambda_{aa} (\mathbf{x}_a - \boldsymbol{\mu}_a) + (\mathbf{x}_a - \boldsymbol{\mu}_a)^T \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b) + (\mathbf{x}_b - \boldsymbol{\mu}_b)^T \Lambda_{ab}^T (\mathbf{x}_a - \boldsymbol{\mu}_a) \right) \right] \propto \\ &\propto \exp \left[-\frac{1}{2} \left(\mathbf{x}_a^T \Lambda_{aa} \mathbf{x}_a - 2 \mathbf{x}_a^T (\Lambda_{aa} \boldsymbol{\mu}_a - \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b)) \right) \right]. \end{aligned}$$

Видно, что искомое распределение с точностью до нормировочной константы имеет вид «экспонента от квадратичной функции». Отсюда заключаем, что $p(\mathbf{x}_a|\mathbf{x}_b)$ является многомерным нормальным распределением. Осталось в последнем выражении выделить полный квадрат и получить параметры распределения $\hat{\boldsymbol{\mu}}, \hat{\Sigma}$:

$$\begin{aligned} \hat{\Sigma}^{-1} &= \Lambda_{aa} \Rightarrow \hat{\Sigma} = \Lambda_{aa}^{-1}, \\ \hat{\Sigma}^{-1} \hat{\boldsymbol{\mu}} &= \Lambda_{aa} \boldsymbol{\mu}_a - \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b) \Rightarrow \hat{\boldsymbol{\mu}} = \Lambda_{aa}^{-1} (\Lambda_{aa} \boldsymbol{\mu}_a - \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b)) = \boldsymbol{\mu}_a - \Lambda_{aa}^{-1} \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b). \end{aligned}$$

В итоге получаем $p(\mathbf{x}_a|\mathbf{x}_b) = \mathcal{N}(\mathbf{x}_a|\boldsymbol{\mu}_a - \Lambda_{aa}^{-1} \Lambda_{ab} (\mathbf{x}_b - \boldsymbol{\mu}_b), \Lambda_{aa}^{-1})$.