

# 機械学習のための線形代数学

山下 智樹

2022年6月29日

## 目次

1	はじめに	1
2	ベクトルの内積と直積	1
2.1	内積	1
2.2	直積	2
3	行列とベクトルの積 $\mathbf{Ax}$	2
4	対称行列と反対称行列 (交代行列)	2
5	2次形式	3
6	ベクトルによる微分	3
6.1	内積の微分	3
6.2	2次形式の微分	4

## 1 はじめに

このノートでは、機械学習を理解するための線形代数の基礎をまとめておく。はじめに、ここで使用する数学記号の表記方法を記しておく。ベクトルは太字の小文字で  $\mathbf{x}$  のように表し、 $N$ 次元ベクトルは  $N \times 1$  行列を用いて縦ベクトルで表現する。

$$\mathbf{x} = (x_1, x_2, \dots, x_N)^T \tag{1}$$

$$= \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{pmatrix}. \tag{2}$$

行列は太字の大文字で  $\mathbf{A}$  のように表記する。 $N \times M$  行列であれば

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1M} \\ a_{21} & a_{22} & \cdots & a_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NM} \end{pmatrix}. \quad (3)$$

## 2 ベクトルの内積と直積

### 2.1 内積

ベクトルの内積はスカラー。

$$\mathbf{x} \cdot \mathbf{y} = \mathbf{x}^T \mathbf{y} \quad (4)$$

$$= (x_1, x_2, \dots, x_N) \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{pmatrix} \quad (5)$$

$$= \sum_{i=1}^N x_i y_i. \quad (6)$$

### 2.2 直積

直積は行列.  $\mathbf{x}$  が  $N$  次元,  $\mathbf{y}$  が  $M$  次元とすると,  $N \times M$  行列になる.

$$\mathbf{x} \otimes \mathbf{y} = \mathbf{xy}^T \quad (7)$$

$$= \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{pmatrix} (y_1, y_2, \dots, y_M) \quad (8)$$

$$= \begin{pmatrix} x_1 y_1 & x_1 y_2 & \cdots & x_1 y_M \\ x_2 y_1 & x_2 y_2 & \cdots & x_2 y_M \\ \vdots & \vdots & \ddots & \vdots \\ x_N y_1 & x_N y_2 & \cdots & x_N y_M \end{pmatrix}. \quad (9)$$

## 3 行列とベクトルの積 $\mathbf{Ax}$

$\mathbf{x}$  を  $N$  次元ベクトル,  $\mathbf{A}$  を  $N$  次正方行列とすると,  $\mathbf{Ax}$  は  $N$  次元ベクトルになり, 第  $i$  成分は

$$(\mathbf{Ax})_i = \sum_{j=1}^N a_{ij} x_j. \quad (10)$$

また,  $\mathbf{A}^T \mathbf{x}$  の第  $i$  成分は  $\mathbf{A}$  を転置させるだけなので簡単で,

$$(\mathbf{A}^T \mathbf{x})_i = \sum_{j=1}^N a_{ji} x_j. \quad (11)$$

## 4 対称行列と反対称行列 (交代行列)

$\mathbf{A}^T = \mathbf{A}$  となる正方行列  $\mathbf{A}$  を対称行列,  $\mathbf{A}^T = -\mathbf{A}$  となる正方行列  $\mathbf{A}$  を反対称行列 (交代行列) という. 交代行列と呼ぶ方が普通.

あらためて,  $\mathbf{A}$  を任意の  $N$  次正方行列とすると, これはいつでも対称行列と反対称行列に分解できる.

$$\mathbf{A} = \frac{1}{2}(\mathbf{A} + \mathbf{A}^T) + \frac{1}{2}(\mathbf{A} - \mathbf{A}^T) \quad (12)$$

$$= \mathbf{A}^S + \mathbf{A}^A. \quad (13)$$

ここで,  $\mathbf{A}^S = \frac{1}{2}(\mathbf{A} + \mathbf{A}^T)$  は対称行列,  $\mathbf{A}^A = \frac{1}{2}(\mathbf{A} - \mathbf{A}^T)$  は反対称行列である.

## 5 2次形式

$\mathbf{x}$  を  $N$  次元ベクトル,  $\mathbf{A}$  を  $N$  次正方行列とすると,  $\mathbf{x}^T \mathbf{A} \mathbf{x}$  を2次形式といい,

$$\mathbf{x}^T \mathbf{A} \mathbf{x} = \mathbf{x}^T (\mathbf{A} \mathbf{x}) \quad (14)$$

$$= \sum_{i=1}^N x_i (\mathbf{A} \mathbf{x})_i \quad (15)$$

$$= \sum_{i=1}^N x_i \sum_{j=1}^N a_{ij} x_j \quad (16)$$

$$= \sum_{i,j=1}^N a_{ij} x_i x_j \quad (17)$$

と表される. ここでは式 (6) と式 (10) の成分表示を用いた.

ここで反対称行列の2次形式  $\mathbf{x}^T \mathbf{A}^A \mathbf{x}$  を考えると,  $\mathbf{A}^A$  の  $ij$  成分と  $ji$  成分は  $a_{ij} = -a_{ji}$  の関係にあるので, 和をとるとキャンセルして0になる. 任意の正方行列は  $\mathbf{A} = \mathbf{A}^S + \mathbf{A}^A$  のように対称行列と反対称行列に分解できることを思い出すと, 結局2次形式をとると対称行列の部分しか残らないので,  $\mathbf{A}$  を対称行列とみなしてよい. この性質を知っておくと, 多変量ガウス分布を理解するのに役に立つ.

## 6 ベクトルによる微分

機械学習ではベクトル表示したパラメータ  $\mathbf{w}$  で何かを微分するような計算が頻繁に出てくるので, いくつかまとめておく. ベクトルで微分するというのは, 簡単に言えば勾配をとればいいので結果もベクトルになる.  $f(\mathbf{w})$  を  $\mathbf{w} = (w_0, w_1, \dots, w_{M-1})^T$  で微分すると下記のようなになる.

$$\nabla f(\mathbf{w}) = \frac{\partial f}{\partial \mathbf{w}} \quad (18)$$

$$= \begin{pmatrix} \frac{\partial f}{\partial w_0} \\ \frac{\partial f}{\partial w_1} \\ \vdots \\ \frac{\partial f}{\partial w_{M-1}} \end{pmatrix}. \quad (19)$$

## 6.1 内積の微分

内積は式 (6) によると,  $\mathbf{x}^T \mathbf{y} = \sum_{i=1}^N x_i y_i$  のように書けるので,

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{y}) = \begin{pmatrix} \frac{\partial}{\partial x_1} (\mathbf{x}^T \mathbf{y}) \\ \frac{\partial}{\partial x_2} (\mathbf{x}^T \mathbf{y}) \\ \vdots \\ \frac{\partial}{\partial x_N} (\mathbf{x}^T \mathbf{y}) \end{pmatrix} \quad (20)$$

$$= \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{pmatrix} \quad (21)$$

$$= \mathbf{y}. \quad (22)$$

同様に,

$$\frac{\partial}{\partial \mathbf{y}} (\mathbf{x}^T \mathbf{y}) = \mathbf{x}. \quad (23)$$

## 6.2 2次形式の微分

$\mathbf{x}^T \mathbf{A} \mathbf{x}$  を  $\mathbf{x}$  で微分することを考える. 勾配の第  $k$  成分は式 (17) を使うと,

$$\frac{\partial}{\partial x_k} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = \frac{\partial}{\partial x_k} \left( \sum_{i,j=1}^N a_{ij} x_i x_j \right) \quad (24)$$

$$= \sum_{i,j=1}^N \left( a_{ij} \frac{\partial x_i}{\partial x_k} x_j + a_{ij} x_i \frac{\partial x_j}{\partial x_k} \right). \quad (25)$$

ここで, 上式右辺括弧の中の第 1 項目は  $i = k$  以外は 0, 第 2 項は  $j = k$  以外は 0 になるので,

$$\frac{\partial}{\partial x_k} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = \sum_{j=1}^N a_{kj} x_j + \sum_{i=1}^N a_{ik} x_i \quad (26)$$

$$= (\mathbf{A} \mathbf{x})_k + (\mathbf{A}^T \mathbf{x})_k \quad (27)$$

$$= \{(\mathbf{A} + \mathbf{A}^T) \mathbf{x}\}_k. \quad (28)$$

途中の式変形には式 (10) と式 (11) を用いた. 従ってベクトル表記では

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = (\mathbf{A} + \mathbf{A}^T) \mathbf{x}. \quad (29)$$

特に  $\mathbf{A}$  が対称行列の場合,

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = 2\mathbf{A} \mathbf{x}. \quad (30)$$