

前言: 学习数学最重要的 principle 是 抓其本质, ~~化繁为简~~ 化繁为简。

一. 向量和尺规

1. 向量的本质

在我学基础代数学的时候, 向量代数的本质被归纳为“空间本质的线性化”。话没错, 但“空间”的意思容易被误解。比如, 我们从二维、三维空间推向量运算, 可以得到正确的 (见下面线性性的说明), 却不利于与几何理解!

加法
倍积
内积
满足线性性 [1] 交换率

II) 倍积: $k \cdot \vec{a}$ 假设函数 $f(x)$ 满足线性性, 则需满足以下两个条件

$$(i) f(\vec{a} + \vec{b}) = f(\vec{a}) + f(\vec{b}) \quad (ii) f(k\vec{a}) = k f(\vec{a})$$

如此一来则 $f(k\vec{a} + k\vec{b}) = k_1 f(\vec{a}) + k_2 f(\vec{b})$ 0

检验 假设运算对象为向量时, 倍积尺规是否满足线性性: 即 $f(\vec{a}) = k\vec{a}$ 时, 容易得到

$$(i) k(\vec{a} + \vec{b}) = k\vec{a} + k\vec{b}, \quad k \cdot k\vec{a} = k \cdot k(\vec{a})$$

∴ 向量的倍积尺规满足线性性, 即有

$$k(c\vec{a} + d\vec{b}) = \cancel{k \cdot c\vec{a} + k \cdot d\vec{b}} = c k\vec{a} + d k\vec{b}$$

内积同样如此. ~~f(x)~~ $f(\vec{x}) = \vec{a} \cdot \vec{x}$

$$则 (i) \vec{a}(\vec{x}_1 + \vec{x}_2) = \vec{a}\vec{x}_1 + \vec{a}\vec{x}_2 \quad (ii) k(\vec{a}\vec{x}) = k\vec{a} \cdot \vec{x}$$

我们得 ~~k\vec{a} \cdot (c\vec{x}_1 + d\vec{x}_2)~~ $\vec{a} \cdot (c\vec{x}_1 + d\vec{x}_2) = c\vec{a} \cdot \vec{x}_1 + d\vec{a} \cdot \vec{x}_2$

二维、三维几何 推广 → 向量尺规 三种尺规确实有很好的几何意义, 如 $\vec{a} \cdot \vec{b} = \frac{1}{2}(|\vec{a} + \vec{b}|^2 - |\vec{a}|^2 - |\vec{b}|^2)$

$$(|\vec{a} + \vec{b}|^2 = |\vec{a}|^2 + |\vec{b}|^2 + 2\vec{a} \cdot \vec{b}, \vec{a} \cdot \vec{b} = (|\vec{a}||\vec{b}| \cos \theta)) \text{ 但!}$$

斜边 下

① 线性性的本质, 一种尺规, 首先可以 ~~理解~~ 分离, 其次可以推

BLOCK

Date

Matrix X Matrix
→ 矩阵乘法

已知 $A[b_1, b_2, \dots, b_n] = A[A_{11}, A_{12}, \dots, A_{1n}]$ 而看注

同样也说明 $Ib=I$ 成立, $IB=B$ 也成立

vector

matrix

更深入一步, 我们可以得到分块矩阵乘法:

$$AB = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} = \begin{bmatrix} A_{11}B_{11} + A_{12}B_{21} & \dots \\ A_{21}B_{11} + A_{22}B_{21} & \dots \end{bmatrix}$$

证明: 先将 B 分列

$$\begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} \Rightarrow \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}, \text{ 根据 } AB = A[B_1, B_2] \dots \text{ ①}$$

$$= [AB_1, AB_2]$$

计算 AB_1 , 将 A 分行

$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \Rightarrow \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, \text{ 根据 } AB_1 = \begin{bmatrix} A_{11} \\ A_{21} \end{bmatrix} B_{11} \dots \text{ ②}$$

$$= \begin{bmatrix} A_{11}B_{11} \\ A_{21}B_{11} \end{bmatrix}$$

其中 $AB_1 = A_{11}B_{11} + A_{12}B_{21}$ (此步省略)

得证!

分块矩阵的分块相乘

证明 9.2

«Matrix computation» P.20.

$$\text{例 3} \quad \begin{bmatrix} A_{11} & A_{12} \end{bmatrix} \begin{bmatrix} B_{11} \\ B_{21} \end{bmatrix} = A_{11}B_{11} + A_{12}B_{21} \quad \text{③}$$

$$\text{证明} \quad \begin{bmatrix} A_{11} \\ \vdots \\ A_{1n} \end{bmatrix} [B_1, \dots, B_r] = C \quad C_{1j} = A_{11}B_{1j} + \dots + A_{1n}B_{nj}$$

④ 分块矩阵相乘的两种形式: $\begin{bmatrix} A & B \\ C & D \end{bmatrix} \begin{bmatrix} E \\ F \end{bmatrix}$

⑤ 矩阵相乘 第三种形式 $\begin{bmatrix} A & B \\ C & D \end{bmatrix} \begin{bmatrix} E & F \\ G & H \end{bmatrix}$

$$E(\text{Elimination}) = \text{Factorization} : A = LU$$

重新考察 $A \rightarrow$ 上三角矩阵的 Elimination 过程是 EA ，即一个 Elimination matrix 与 A 相乘。那么如何反过求操作呢？
 $L \xrightarrow{\text{how}} A$?

$$\begin{aligned} EA &= U & \text{则} & \\ E^{-1}U &= A & \text{即} & A = E^{-1}U \end{aligned} \quad \left. \begin{array}{l} \text{消元过程} \\ \text{反求解} \end{array} \right\}$$

先将 A 化为上三角矩阵 U ，用 Elimination matrix E

$$\text{则 } A = E^{-1}U, \text{ 而非 } A = LU$$

以上是只需要一个 E ，即只需要作一次 Elimination 情况下，一般 n 阶的线性方程组需要作 $n-1$ 次 Elimination。

$$E_1 \dots E_2 E_1 A = U \quad \text{则 } A = (E_1^{-1} E_2^{-1} \dots E_n^{-1}) U$$

$$\text{记作 } A = LU$$

注 E_i^{-1} 也是矩阵即 L 的下三角矩阵
 (同样 L 也是)

例子

$$A = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 2 & 1 \\ 0 & 1 & 2 \end{bmatrix} \rightarrow U = \begin{bmatrix} 2 & 1 & 0 \\ 0 & \frac{3}{2} & 1 \\ 0 & 0 & \frac{5}{2} \end{bmatrix}$$

$$R_2 - \frac{1}{2}R_1$$

$$R_3 - \frac{1}{2}R_2$$

$$L = \begin{bmatrix} 1 & 0 & 0 \\ \frac{1}{2} & 1 & 0 \\ 0 & \frac{2}{3} & 1 \end{bmatrix} \quad A = LU$$

L 与 U 的构成 (无 Row Exchange 情况下)

- 1) 当 A 的一行以 0 开头时， L 的该行也是 (无需 subtract)
 当 A 的一列以 0 开头时， U 的该列也是 (不用消元)
 (中间的会在 Elimination 过程中消去)

- 2) L 的主对角线肯定都是 1， U 则不然，如何把 U 归成 1 呢？
 这里就存在一种特殊矩阵：对角矩阵

TRANSPOSES 和 PERMUTATIONS

$$(A^T)_{ij} = A_{ji} \quad \text{转置}$$

性质举例

T三角矩阵上三角 (但 inverse 仍是下三角)

$$(AB)^T = B^T A^T$$

$$(A^{-1})^T = (A^T)^{-1}$$

i) 证明 $(AB)^T = B^T A^T$, 首先看 $(Ax)^T = x^T A^T$

我们知道 Ax 是 $\sum_{i=1}^n A(i, i) x_i$

$$x^T A^T \text{ 是 } \sum_{i=1}^n x_i^T A^T(i, i)$$

得到 $(Ax)^T = x^T A^T$ 之后, 将 B 按列拆分成很多证明 $(AB)^T$

我们发现, 矩阵的三种拆分是用来证明很多东西的利器!

$$AB = [Ax \quad Ax_2 \quad \dots] \text{ 转置为 } \begin{bmatrix} x_1^T A^T \\ x_2^T A^T \\ \vdots \end{bmatrix} = B^T A^T$$

将 B 按列拆分

正好是 B^T 按行拆分的乘法

ii) $A^{-1}A = I \Rightarrow A^T(A^{-1})^T = I^T = I$

$$\therefore (A^T)^{-1} = (A^{-1})^T$$

同时出现的
直观意义: 转置和先后顺序无关

转置到底拿来干什么?

$$(Ax)^T y = x^T (A^T y)$$

这是在 EE-机械: 都很有用... 无怪...

Symmetric Matrix: $A^T = A$ (在转置下定义的)

$$\text{根据 } A^{-1} = (A^T)^{-1} = (A^{-1})^T$$

∴ 对称矩阵的逆也是对称的

若有一矩阵 R , $R^T R$ 是对称矩阵

$$R^T R \quad (R^T R)^T = R^T (R^T)^T = R^T R$$

RR^T 也一样

三. 向量空间与子空间

$\mathbb{R}^n$ a real vector space is a set of ~~two~~ vectors "together" with rules for vector addition and multiplication by real numbers.

① 加号. 向量空间 m. f. 又两 vector 环是

实向量... (进一步探讨这里先停止)

二种运
算闭包

Subspace (子空间): 对 线性组合 闭包. 即若 $\vec{v}$ 在子空间中
i. $\vec{v} + \vec{w}$ 在子空间中

ii. $c\vec{v}$ 在子空间中, c 为任意 scalar

对于一个 $\mathbb{R}^3$, 它可能有以下四种子空间

(L) Any line through $(0,0,0)$

(P) Any plane through $(0,0,0)$

(Z) Single vector $(0,0,0)$

(R) the whole space

注. part of the line or plane 都不满足条件!

讨论 $Ax=b$ 的另一种观察现象:

~~若 x 任意, 则 b 取 A 的列的线性组合.~~

对于一个矩阵 A , 我们将 A 的列向量所表示的向量空间称作 column space, 记作 $C(A)$

这样, 解方程可理解为 b 是不是在 $C(A)$ 上了. 这是另一种已知的, 若采用类似的方式.

若 A 满秩, 则必是可行

若 A 不满, $\begin{cases} \text{若 } b \text{ 可以被表示 (即 elimination 至少一个为 0)} \\ \text{若 } b \text{ 不可被表示 (即 } \checkmark \checkmark \checkmark \checkmark \text{ 都不为 0)} \end{cases}$

$Ax=0$ 的解组成的空间是 nullspace, 记作 $N(A)$

为什么是一个空间呢? 倘若 x, y 满足 $Ax=0, Ay=0$ 则

x, y 满足 线性组合 子空间的条件. 即:

$x+y$ 也是它的解

$c x$ 也是它的解

∴ $Ax=0$ 的解构成一个子空间.

很容易，~~但是~~ 子空间 $S = x_1 \begin{bmatrix} -2 \\ 1 \\ 0 \end{bmatrix} + x_2 \begin{bmatrix} 3 \\ 1 \\ 1 \end{bmatrix}$ 为例
它不含原点的所有三维向量，如向量 $\begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix}$

满足 2, 3 component 之后， x_1, x_2 也就定了，不用再满足 first component 了。

但已知它能满足一个子空间，问：任意 2 个向量
向量 $\begin{bmatrix} a \\ 0 \\ 1 \end{bmatrix} \begin{bmatrix} b \\ 0 \\ 1 \end{bmatrix}$ 是否都能形成一个子空间？
线性组合 = 二维

答：不行。这 2 个向量可以反推一个 $Ax=0$ 的方程，

即 $x - ay - bz = 0$ ，例如 $[1, -a, -b]$

这样 $\begin{bmatrix} a \\ 0 \\ 1 \end{bmatrix} \begin{bmatrix} b \\ 0 \\ 1 \end{bmatrix}$ 的线性组合构成的子空间恰好是

$Ax=0$ 的 nullspace. A 与 nullspace matrix (描述其构成的 matrix)
例如关系 $A = \begin{bmatrix} 1 & -a & -b \\ 0 & 0 & 0 \end{bmatrix}$, $N = \begin{bmatrix} -F \\ I \end{bmatrix}$

百进平说，这个问题可以理解为如下。

当 $m \leq n$ 时， $m \times n$ 向量后秩为 k ($k \leq m$)。则
这 $m \times n$ 向量可 ~~由秩为~~ 线性组合可以构成一个
 k 维的子空间

$$\begin{array}{c} \downarrow \\ \left[\begin{array}{ccc|ccc} I_k & 0 & & & & \\ & \times & & & & \\ & \times & & & & \\ & \times & & & & \\ & \times & & & & \\ & \times & & & & \end{array} \right] \begin{array}{c} \rightarrow \text{秩} \\ \text{Elimination} \end{array} \\ \downarrow \\ \left[\begin{array}{ccc|ccc} 0 & 0 & 0 & 0 & 0 & 0 \end{array} \right] \end{array}$$

Rank 的一些性质

两个向量的外积形式，~~秩~~ uv^T ，如

$$\begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix} \begin{bmatrix} 1 & 3 & 10 \end{bmatrix} = \begin{bmatrix} 1 & 3 & 10 \\ 2 & 6 & 20 \\ 3 & 9 & 30 \end{bmatrix} \quad \text{秩为 1 秩一定为 1} \quad \text{①}$$

~~秩为 1~~
秩为 1：矩阵的秩 = 列秩！

① 矩阵秩为 2 种理解，列的得到行，列都是倍数关系

★ 对于上述情况, 此 $m \times n$ 的 A 的 column space 由 k 个相互独立的 vector 构成, 是 $\mathbb{R}^n$ 一个 dimension 为 k 的子空间. 这 k 个相互独立的 vector $\begin{bmatrix} | & | & | \end{bmatrix}$ 构成的 sequence (通常, 矩阵表示) 叫作 set basis, 记作 $\{ \}$.
 $\Rightarrow$ vector 构成的 base

与 A 相关的空间

1. Row space $C(A^T)$, $\mathbb{R}^n$ 的子空间
2. Column space $C(A)$, $\mathbb{R}^m$ 的子空间
3. null space $N(A)$, $\mathbb{R}^n$ 的子空间
3. left nullspace $N(A^T)$, $\mathbb{R}^m$ 的子空间 $A^T y = 0$ 即 $y^T A = 0$

$\begin{bmatrix} \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots \end{bmatrix}$
 $n \times m$ 的 A

2个 beautiful info

a. Row space 与 Column space 有相同的 dimension (都 = r)

b. nullspace dimension 为 $n-r$, 即 $\text{Rank}(A) + \dim N(A) = n$
 left nullspace dimension 为 $m-r$, $\text{Rank}(A) + \dim N(A^T) = m$

A 的 column space 维数与 A^T 的 column space 维数相等

$$\therefore C(A) \dim r = C(A^T) \dim r, C(A) \dim r = C(A^T) \dim r$$

$$\therefore C(A^T) \dim r = C(A) \dim r \quad \text{行与列互换}$$

$$\therefore C(A) \dim r = C(A^T) \dim r$$

注意: 两个维数相等, basis 不同, 但

$$A = \begin{bmatrix} 2 & 3 \\ 4 & 6 \end{bmatrix} \quad R = \begin{bmatrix} 2 & 3 \\ 0 & 0 \end{bmatrix} \quad (\text{即 Row space 相同})$$

得到 A 与 R 的
 4个 space 的维数
 都相等

同样

由 b 证明, a 是 n , b 以 R 来证, 就证明了 A .

于是就有了 A 的不同 space 之间良好的关系.

orthogonality

12. 正交 (ORTHOGONALITY)

空间/level上的正交: $\vec{v} \cdot \vec{w} = 0$ or $\vec{v}^T \vec{w} = 0$, for all $\vec{v}$ in V and all $\vec{w}$ in W , 则 V 与 W 正交

1. A 的 Row space 与 $N(A)$ 正交: $AX=0$, 故 N 中的任一 vector 都与 A 的 行向量点积为 0. 故 (A^T) 与 $N(A)$ 正交

2. 不仅如此! 它们不仅 Orthogonality, 而且 orthogonal complements! 即 正交互补 空间。因为维数相加刚好是 n : $(r + (n-r))$ (注: 补向量空间作用已补充2)

正交互补表示: $V^\perp$ 表示 V 的正交互补空间

$$N(A)^\perp = C(A^T)$$

$$C(A^T)^\perp = N(A)$$

补充1: 空间正交 则两空间相交的 vector 必定是 $\vec{0}$.

证: 若两空间相交于 $\vec{v}$, 则 $\vec{v} \cdot \vec{v}$ 为两空间 行向量点积为 0, 故 $\vec{v} = \vec{0}$.

∴ 一堵墙和地面不是正交空间!

补充2: $A\vec{x} = \vec{0}$ 则 $\vec{x}$ 与 A 的 Row space 正交的向量, 即与每一 Row 的点积都为 0, 则它在 $N(A)$ 中. 因为满足 $A\vec{a} = \vec{0}$ 则 $\vec{a}$ 必是 $N(A)$ 中的某一个向量

ii) 同样, 与 $N(A)$ 正交的向量必在 $C(A^T)$ 中. 反证, 若存在不是 $C(A^T)$ 的向量 $\vec{v}$, 则 我们可以将其作为一个 row 加入 A 中, 由于 $\vec{v}$ 不在 $C(A^T)$ 中, 则 Row space 的 dim 会变成 $r+1 \neq r$

Fundamental Theorem of Linear Algebra (part 2)

$$N(A)^\perp = C(A^T)$$

$$N(A^T)^\perp = C(A)$$

N (space) 和 Row space 是 $\mathbb{R}^n$ 中的正交互补空间

Left nullspace 和 Column space 是 $\mathbb{R}^m$ 中的正交互补空间

定理: n 个线性无关的向量可作为 $\mathbb{R}^n$ 的基 (basis)

$C(A^T)$ 中的 r 个 vector, 加上 $N(A)$ 中的 $(n-r)$ 个 vector, 这 n 个都是线性无关的, 故可作为 $\mathbb{R}^n$ 的基。

$\therefore \begin{bmatrix} I_r & 0 \\ 0 & 0 \end{bmatrix}$ 是个满秩矩阵 $\rightarrow$ 记号, 当然可分母。

$\hookrightarrow$ 已证明, 但是意义何在?

$\mathbb{R}^n$ 中的任意向量 $\vec{x} = \vec{x}_r + \vec{x}_n$
 $A\vec{x}_n = 0$

① 所有列向量被 A 乘, $A\vec{x}_r = \vec{b}$
 空间 $\Rightarrow$ 都在 $C(A)$ 中

② 所有列空间向量都来自 $A\vec{x}_r$

③ 又由 A 乘 $\vec{x}_n \Rightarrow$ 都来自 $C(A^T)$

$C(A^T)$ 或 $C(A)$ 值域 且 $\vec{x}_n$

证明:

任何满足 $P^2 = P$ 的 P , 其秩为 1. 我们猜 $(I-P)$ 也是一个 projection matrix, 它的作用应该是把 b 投影到 A 的正交互补空间, 其投影为 e

$$(I-P)b = b - Pb = e$$

那么 $I-P$ 怎么证明呢, 证明它能够将任意的向量投影到 A 的正交互补空间里呢?

证: 对任意向量 b , 都能投影为 e
 e 在 A 的正交互补空间里!

补充说明: $P^2 = P$ 因为投影 2 次, 第 2 次无意义

$$\frac{A A^T}{A^T A} \frac{A A^T}{A^T A} = \frac{A A^T}{A^T A}$$

2) 投影到 $C(A)$

problem: given $A_1, A_2, \dots, A_n$ in $\mathbb{R}^m$, assume these A 's are linearly independent. Find the combination $\hat{x}_1 A_1 + \hat{x}_2 A_2 + \dots + \hat{x}_n A_n$ that is closest to a given b .

$n=1$ 即为投影到 (1) 上的问题. 现在要找 $n>1$ 时的 $\hat{x}$
 $\hat{x} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n]^T$

同理, 这样的 $A\hat{x}$ 只有一条, 即可列方程求 $\hat{x}$.

$$A^T(b - A\hat{x}) = 0 \quad \text{即每一个 } A_i \text{ 都与 } b - A\hat{x} \text{ 正交为 } 0$$

$$\begin{aligned} \therefore A^T A \hat{x} &= A^T b & \text{若 } A^T A \text{ 可逆则 } \hat{x} &= (A^T A)^{-1} A^T b \\ P &= A(A^T A)^{-1} A^T & \left. \begin{array}{l} \text{5-} \\ \text{时的} \\ \text{矩阵} \end{array} \right\} \\ P &= A(A^T A)^T A^T \end{aligned}$$

① A 的 (column 空间) 正交补, 肯定在 A 的 left nullspace 中, 即 $N(A^T)$, 由方程组表示 $A^T(b - A\hat{x}) = 0$

LEAST SQUARES APPROXIMATIONS 最小二乘法

straight 书中将 $b - Ax$ 称作 "error" 是有原因的。在书
~~给~~ 给定 A, b 求 b 在 $C(A)$ 上的投影 p , 投影矩阵 P 的
 时候, A 通常是 $m \times n$ ($m > n$) 的情况, 即 A 长或下面这个样子

$$\begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix}$$

这样的 $Ax = b$, 常常是无解的, 即 b 在
 $C(A)$ 之外 (不能用 A 的列向量线性表示)

但是, 我们仍想找一个 x 使得 Ax 与 b 最接近。怎么找?
 找它的投影最好... 书上说...

书上将 $b - Ax$ 称作 error, 这个最小则

$$A^T(b - Ax) = 0 \quad \text{即} \quad \cancel{A^T A x} = \cancel{A^T b}$$

$$\text{即} \quad A^T A x = A^T b \quad (\text{可以解 } Ax \text{ 为两边用 } A^T \text{ 乘})$$

这个解叫做 least square solution.

这个有什么用呢? 除了求投影

Application: Find a straight line to ~~the~~ _m points.

eg find the closet line to the points $(0, 6), (1, 0), (2, 0)$

解: 假设直线为 $b = C + Dt$ 列方程组

$$C + D \cdot 0 = 6$$

$$C + D \cdot 1 = 0$$

$$C + D \cdot 2 = 0$$

$$\begin{bmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{bmatrix} \begin{bmatrix} C \\ D \end{bmatrix} = \begin{bmatrix} 6 \\ 0 \\ 0 \end{bmatrix}$$

根据线性方程组理论, b 显然不在 A 的列空间内。

$Ax = b$ 不可解! ⁽¹⁾

用投影的方法求 $\hat{x} = (A^T A)^{-1} A^T b$

是不是很神奇! 当 $m=2$ 的时候 就是找开一条
 最好的直线了!

(1) 可将列向量 b 排成一排进行 elimination, 即可发现无解了


也可以说明 b 不在列空间内; 也可以简单地看 $\text{rank}[A] < \text{rank}[A, b]$ 不满足 $\text{rank}[A] = \text{rank}[A, b]$

a. 与 Fundamental Theorem of Linear Algebra 的对象 A 不同. 最小二乘 (指的是 projection 方法) 的对象是 A 的 nullspace 实际上只有一个点 zero!

依据: A 的 Column vector 之间是 independent, 这样 $(A^T A)^{-1}$ 才有意义.

b. 在 Fundamental Theorem of Linear Algebra 中, 我们把重心放在 AX 上, 而非 b 上, 研究的却是有解的情况. 即: 存在 $x = x_r + x_n$ 从而每一个能够由 A 的 column vector 线性表示的 b , 都是来自于 A 的行空间 $C(A^T)$ 的一个向量.

而在这里, 我们研究的是 不在 $C(A)$ 中的向量 b , 我们将其分解为 $b = AX + e$, 其中 e 在 $N(A^T)$ 中.



扩展: 从一维函数到多维 Least squares 匹配问题.

$$y = C^T p t_1 + c t_2$$

这样 A 的 independent column vector 只是从 2 个变成了 3 个.

ORTHOGONAL BASES AND GRAM-SCHMIDT

- 1) 正交简化过程, 除了能揭示线性代数和事实。
- 2) 如何构造正交向量。

确实, 我们已经在非正交基上的一些问题 (如投影)

(求解这系统花了不少时间, 而且常无解)

力的各个 space 一般都是非正交基)

但是, 正交基能带来很多好的运算性质!

定义: "orthonormal" given $q_1, \dots, q_n$ if

$$q_i^T q_j = \begin{cases} 0 & \text{when } i \neq j \text{ (orthogonal vectors)} \\ 1 & \text{when } i = j \text{ (unit vectors: } \|q_i\| = 1) \end{cases}$$

3) 由 orthonormal vector columns 组成的矩阵叫 Q 表示

$$Q = \begin{bmatrix} | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \end{bmatrix} \quad \begin{matrix} m \times n \\ m \times n \end{matrix}$$

性质 $Q^T Q = I \Leftrightarrow$ orthonormal

$$Q^T Q = \begin{bmatrix} -q_1^T- \\ -q_2^T- \\ \vdots \\ -q_n^T- \end{bmatrix}_{n \times n} \begin{bmatrix} | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \\ | & & | \end{bmatrix}_{n \times n} \begin{matrix} q_1 \\ q_2 \\ \vdots \\ q_n \end{matrix} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} = I$$

~~证明~~

根据在 projection - 一种证明而证明, $Q^T Q$ 为 ~~对称矩阵~~ 秩为 n ^①

因此不是显而易见的么...

$I_{n \times n}$

因此不仅是 对称矩阵, 它还是个 I ^②

不过话说, 性质与前面证明的不冲突!

另, 由于 $Q^T Q = I$

3) 何 Q 为 $n \times n$ 时, $Q^T = Q^{-1}$, transpose = inverse

格拉姆-施密特正交化

给三个线性无关向量 a, b, c 将其代成 orthogonal 关系

1. c 为 ~~orthogonal~~ orthogonal
2. 每个 vector / ||vector||

$$A = a$$

$$B = b - A \frac{A^T b}{A^T A} \quad (\text{error})$$

$$C = c - [A \ B] \frac{[A \ B]^T c}{[A \ B]^T [A \ B]}$$

$$= c - A \frac{A^T c}{A^T A} - B \frac{B^T c}{B^T B}$$

D (if exists)

$$q_1 = \frac{A}{\|A\|}$$

$$q_2 = \frac{B}{\|B\|}$$

$$q_3 = \frac{C}{\|C\|}$$

QR分解

一个矩阵 A ，经过 Gram-Schmidt 正交化之后，从 $[a \ b \ c]$ 得到

$Q = [q_1 \ q_2 \ q_3]$ 。从 A 到 Q 的过程，由于 ~~正交化~~ a, b, c 被

q_i 表示，肯定有第三个 matrix R ，使得 A 与 Q 联系起来。

这就是 Algebra 中第二个矩阵分解算法：QR分解！

在之前计算 b 的 orthonormal 向量组代为空间 π 投影时，我们求得

$$\hat{x} = Q^T b = \begin{bmatrix} -q_1^T \\ -q_2^T \\ \vdots \\ -q_n^T \end{bmatrix} b = \begin{bmatrix} q_1^T b \\ q_2^T b \\ \vdots \\ q_n^T b \end{bmatrix}$$

$$\hat{y} = Q \hat{x} = \begin{bmatrix} | & | & \dots & | \\ q_1 & q_2 & \dots & q_n \\ | & | & \dots & | \end{bmatrix} \begin{bmatrix} q_1^T b \\ q_2^T b \\ \vdots \\ q_n^T b \end{bmatrix} = \underline{q_1(q_1^T b) + q_2(q_2^T b) + \dots + q_n(q_n^T b)}$$

当 Q 为方阵时，即 b 的投影是其本身时。
(~~投影不是方阵，若 b 在 π 内或 b 在 Q 空间内， $b = p = Q \hat{x}$)~~)

$$b = q_1(q_1^T b) + q_2(q_2^T b) + \dots + q_n(q_n^T b)$$

这是向量分解的基础！

五. DETERMINANTS 行列式

行列式能干嘛呢?

1. 与 inverse 的关系.

i) 与 inverse 一样, 不是矩阵才有 $1/a$

ii) $|A| \neq 0$, A 才有 A^{-1}

iii) A^{-1} 的 $\det A^{-1} = 1/\det A$. 取集 ii) $\det A^{-1}$ 无意义若 $\det A = 0$

这样当 $\det A \neq 0$ 时 $Ax=b$ 就能直接求为 $x = A^{-1}b$

2.

3. 使得 $A - \lambda I$ 为 singular, $\det(A - \lambda I) = 0$ 的 λ 是 A 的特征值!

定义. The product of the pivots is the determinant.

eg) $A = \begin{bmatrix} a & b \\ c & d \end{bmatrix}$ $\det A = a(d - \frac{c}{a}b) = ad - bc$

至于 $n \geq 2$ 的 $\det$, 我们不算给出来的公式 (见前有归纳证明, 太复杂了). 我们通过给出 $\det$ 的性质来求 $\det$ 的值.

性质:

1. $\det I = 1$ 符定义

2. 斜对称性 (reversal): A 行互换 A' , $\det A' = -\det A$

(这样就可以求任意 permutation matrix 了, 只要数数换了几次行)

3. $\det$ 是 A 的行向量的 ^多线性函数

$$\det \begin{bmatrix} a_1 \\ \vdots \\ \lambda a_i + \mu a_j \\ \vdots \\ a_m \end{bmatrix} = \lambda \det \begin{bmatrix} a_1 \\ \vdots \\ a_i \\ \vdots \\ a_m \end{bmatrix} + \mu \det \begin{bmatrix} a_1 \\ \vdots \\ a_j \\ \vdots \\ a_m \end{bmatrix}$$

对每一行都是线性性, (超过 2 个变量称为多线性性了)

故 $\det$ 是行的斜对称、多线性性函数

计算 determinant. PERMUTATIONS & COFACTORS

引入一个矩阵

$$\begin{bmatrix} 2 & -1 & 0 & 0 \\ -1 & 2 & -1 & 0 \\ 0 & -1 & 2 & -1 \\ 0 & 0 & -1 & 2 \end{bmatrix}$$

方法1. $\det P, \det A = \det L \det U$ ($\det L = 1$)很容易得到 $\det A = 5$ (实际上 A 是 $n \times n$, $\det A = n+1$)注: 关于 permutation, 根据 $\det$ 的性质, 它就是 I 经过行交换后得到的. 换奇数次为 -1 , 偶数次为 1 .方法2: 以 $\det$ 的三个性质为依据. 以 2×2 Matrix 为例. 得到行列式的公式.

$$\begin{vmatrix} a & b \\ c & d \end{vmatrix} = \begin{vmatrix} a & 0 \\ c & d \end{vmatrix} + \begin{vmatrix} 0 & b \\ c & d \end{vmatrix} \quad (\text{行列式的线性性})$$

$$= \begin{vmatrix} a & 0 \\ c & 0 \end{vmatrix} + \begin{vmatrix} a & 0 \\ 0 & d \end{vmatrix} + \begin{vmatrix} 0 & b \\ c & 0 \end{vmatrix} + \begin{vmatrix} 0 & b \\ 0 & d \end{vmatrix}$$

同列有之间是线性相关的, 所以 $\det = 0$

$$= \begin{vmatrix} a & 0 \\ 0 & d \end{vmatrix} + \begin{vmatrix} 0 & b \\ c & 0 \end{vmatrix} = ad - bc$$

推广到 $n \times n$ 矩阵, 可发现 $\det$ 值由以下规则构成:① 每行都出现一个元素构成一个乘积, 这些元素两两之间不能存在同列, 故共有 $n!$ 个乘积.

② 一个乘积的符号由它对应的 permutation 矩阵决定, 如

$$\begin{bmatrix} 0 & b \\ c & 0 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} b & 0 \\ 0 & c \end{bmatrix},$$

$$\therefore \det A = \sum (\det p) a_{1p_1} a_{2p_2} \dots a_{np_n} = \text{BIC FORMULA}$$

7. EIGENVALUES AND EIGENVECTORS 特征值/向量

除了线性方程 $Ax=b$ (被称作 稳定状态问题, steady state problem), 还有一类方程 $dx/dt = Ax$ 而这是随时间变化的, 称作 动态问题, dynamic problem

⇒ 需要 eigenvalue 和 eigenvector

另外, eigenvalue, eigenvector 在 matrix power, A^k 上很有用

特征向量是什么?

绝大多数向量被 A 乘后 (Ax) 会改变方向, 例外就是 A 的特征向量, 即 $Ax = \lambda x$

λ 就是特征值

表明这个向量是变长还是变短 ($|\lambda| > 1$?), 有没有变方向 ($\lambda < 0$?)

很自然的我们会有 2 个问题:

1. 给定一个 A , 它的特征值有几个, 特征向量有几个, 如何求?
2. A 的特征向量形成的子空间维数是多少?

完美解决这两个问题是称作 eigenvector 与 eigenvalue 的关键

定理 1. λ 是 A 的特征值 $\Leftrightarrow \det(A - \lambda I) = 0$ (characteristic polynomial 特征多项式)

⇒ λ 是 A 的特征值 则 $(A - \lambda I)x = 0$ 有非零解, 故 $\det(A - \lambda I) = 0$ (否则若只有零解, 则 $x=0$, 不满足①)

← $\det(A - \lambda I) = 0$, 则 $(A - \lambda I)x = 0$ 有非零解, 故 λ 为 A 的特征值

注①, 特征向量不为零, 零向量作为特征向量不具备任何意义, 而特征值可以是 0 $\Leftrightarrow \det A = 0$

定理 1 解决了给定一个 A 有几个 λ 的问题。答案是 n 个, 因为 $\det(A - \lambda I) = 0$ 得到, 根据 $\det$ 的公式, λ 最高次为 n .

若能表示则是很棒的事情，很出乎意料了：

$$\vec{x} = a\vec{x}_1 + b\vec{x}_2, \quad \vec{x}_1, \vec{x}_2 \text{ 是 } A \text{ 的 eigenvectors, 线性无关}$$

$$\text{则 } A\vec{x} = A(a\vec{x}_1 + b\vec{x}_2) = a\lambda_1\vec{x}_1 + b\lambda_2\vec{x}_2$$

∴ 若 A 的 eigenvectors 可作 $\mathbb{R}^n$ 的基，即它们之间线性无关，会是很好的性质！我们把这称作可对角化的充分必要条件。


在继续讨论之前，先明确一点：初等变换及代入。 e.g.

$$A = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \quad \begin{vmatrix} 1-\lambda & 1 \\ 1 & 1-\lambda \end{vmatrix} = \lambda(\lambda-2)$$

$$\text{而 } U = \begin{bmatrix} 1 & 1 \\ 0 & 0 \end{bmatrix} \quad \begin{vmatrix} 1-\lambda & 1 \\ 0 & -\lambda \end{vmatrix} = \lambda^2 - \lambda - 1 \quad \lambda \text{ 不同解。}$$

∴ λ 的情况与 $\text{Rank}(A)$ 无关？

A : A (λ 在对角线上形成 Λ 的对称矩阵)



$$U \quad \Lambda' \neq \Lambda$$

唯一有穷解是：当 $\det A = 0$ 时，即 A 可逆时， 0 是 A 的特征值！

∴ 若我们想通过研究 A ，得到 λ 的特征，再得到 $\vec{x}$ 的特征，
也的否撑起整个 $\mathbb{R}^n$ 空间，是行不通的 ... ②



我们只证明，若 A 有 n 个不同的 λ ，则 ~~我们~~ eigenvectors 的撑起 $\mathbb{R}^n$ ！
② 待进一步研究，这仅是猜想。

—— 比较 A 与 Λ ，很显然，它们有相同的特征值，那么 eigenvectors 呢？

求 λ_i 对应的 eigenvectors

$$(\Lambda - \lambda_i I) \vec{x}_i = 0$$

第 i 行 $\begin{bmatrix} -\lambda_i & \lambda_i & & \\ & & \ddots & \\ & & & \lambda_i - \lambda_i \\ & & & & \lambda_n - \lambda_i \end{bmatrix} \vec{x}_i = 0 \Rightarrow \vec{x}_i = k \begin{bmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix}$... 第 i 行

∴ Λ 的特征向量为 I 的列向量，与 A 不同。

	eigenvectors	Matrix	eigenvalue
Λ	I		Λ
A	S		Λ

—— S 的列向量可以随意 scalar，仍满足 $S^{-1}AS = \Lambda$

$$[x_1, x_2, \dots, x_n]^T A [x_1, x_2, \dots, x_n] = \Lambda$$

$$[ax_1, bx_2, \dots, cx_n]^T A [ax_1, bx_2, \dots, cx_n] = \Lambda$$

∴ 仍是 A 的特征向量 $\in N(A - \lambda I)$

极端情况就是 $A=I$ 时，所有向量都是 A 的特征向量...

—— 除了 S ，还有没有其它矩阵能对角化 A ？

假如存在这样的矩阵 S' ， $AS' = S'\Lambda$ 则取 S' 的列 s'_i

$$As'_i = \lambda'_i s'_i \quad \text{由此推出 } s'_i \text{ 与 } \lambda'_i \text{ 只可能是 } A \text{ 的特征向量与 values.}$$

$$\text{故 } S' = S \quad \text{即}$$

只有 S 能对角化 A

1. matrix power 递推 $u_{k+1} = A u_k$, 则 $u_k = A^k u_0$

关键想法: u_0 用它的 eigenvectors 表示.

步骤如下:

1. 找到它的 eigenvalues 和 eigenvectors (需要 independent)
2. u_0 表示成 S 的线性组合, $u_0 = c_1 \vec{x}_1 + \dots + c_n \vec{x}_n$
3. $u_k = A^k u_0 = c_1 \lambda_1^k \vec{x}_1 + \dots + c_n \lambda_n^k \vec{x}_n$

用矩阵的语言描述如下:

$$2. u_0 = \begin{bmatrix} | & | & & | \\ x_1 & x_2 & \dots & x_n \\ | & | & & | \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_n \end{bmatrix}, \text{ 则 } u_0 = S \vec{c}$$

$$3. u_k = A^k u_0 = S \Lambda^k S^{-1} S \vec{c} = S \Lambda^k \vec{c}$$

$$S \Lambda^k \vec{c} = c_1 \lambda_1^k \vec{x}_1 + c_2 \lambda_2^k \vec{x}_2 + \dots + c_n \lambda_n^k \vec{x}_n$$

目的: 即将 u_k 表示成 A^k 的 eigenvectors 线性组合

一个 定理: 不管矩阵有无重复特征值, 都判断矩阵是否可对角化并不难:

1. 我们已证明有 λ_1, λ_2 之间的 eigenvectors 必定线性无关. 因而有, 重复矩阵有 n 个不同 λ , 则 S 能表示整个 $\mathbb{R}^n$, 即有 n 个 eigenvectors independent

2. 同一个 λ 若有 n 个 eigenvectors, 则由于这些向量 $\in N(A - \lambda I)$ 它们之间线性无关.

综上, 一个矩阵可对角化的充分条件是: 每个特征值对应的特征向量线性无关的总个数等于该特征值的重数. ~~见下页~~

从而任何矩阵有 n 个线性无关向量特征.

Symmetric Matrix 对称矩阵

Symmetric Matrix is the most important matrix in the world

— Strang

Projection Matrix:

1) 若投影到 line 上 $P = \frac{AA^T}{A^T A}$

$$A = (a_1 \dots a_n)^T \quad \text{则} \quad A = a_1 a_1^T = \begin{bmatrix} a_1 \\ \vdots \\ a_n \end{bmatrix} [a_1 \dots a_n]$$

$$A) \quad a_i a_j = a_j a_i$$

$$a_j a_i = a_i a_j = A_{ij}$$

故 $P = P^T$, P 为对称矩阵

且有 eigenvalue $\begin{cases} 0 & Px=0 \quad (\text{当 } x \perp A \text{ 向量}) \\ 1 & Px=x \quad (\text{当 } x \text{ 与 } A \text{ 向量重合}) \end{cases}$

2) 若投影到 n 维空间, 则

$$P = \frac{AA^T}{A^T A} = A(A^T A)^{-1} A^T$$

$$P^T = A((A^T A)^{-1})^T A^T = A(A^T A)^{-1} A^T = A(A^T A)^{-1} A^T = P$$

$\therefore P$ 为对称矩阵

对称矩阵的美丽性质:

Spectral theorem: Every symmetric matrix has the factorization

$A = Q \Lambda Q^T$, with real eigenvalues in Λ and orthonormal eigenvectors in Q :

$$A = Q \Lambda Q^{-1} = Q \Lambda Q^T, \text{ with } Q^{-1} = Q^T \text{ 即 } Q Q^T = I$$

证明分两步:

1. 有 n 个不同 eigenvalues 时, 不同 eigenvector independent (上一节已证) 且 orthogonal. (这一节证)

2. 即使 eigenvalue 有重根, 仍归有 n 个 orthonormal eigenvectors

(不同 λ 的 eigenvectors 之间正交, 同一 λ 的 eigenvectors 个数 = 重数, 且正交?)

当从一般矩阵 (可时化条件满足) $\rightarrow$ 对称矩阵

$$A = S \Lambda S^{-1}$$

$$A = Q \Lambda Q^T$$

有什么优势呢, 作为对称矩阵?

$$A = Q \Lambda Q^T = \begin{bmatrix} x_1 & x_2 & \dots & x_n \\ | & | & & | \\ 1 & 1 & & 1 \end{bmatrix} \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \dots & \\ & & & \lambda_n \end{bmatrix} \begin{bmatrix} -x_1^T \\ -x_2^T \\ \vdots \\ -x_n^T \end{bmatrix}$$

$$= \lambda_1 x_1 x_1^T + \lambda_2 x_2 x_2^T + \dots + \lambda_n x_n x_n^T \quad \text{此即为谱分解!}$$

其中每一个 $x_i x_i^T$ 都可作为一个 projection matrix (投影到 x_i 这条线上的 P)

$$A = \lambda_1 P_1 + \lambda_2 P_2 + \dots + \lambda_n P_n$$

解方程组 $\rightarrow$ 解成行列式形式

在行列式中也有
重数应用

对称矩阵属于同一 λ 的

eigen vectors 之间的 independent 向量

是正交的 gram-schmidt 正交化的, 正

交化之后还是这个 λ 的特征向量

(不同 λ 之间正交化后就不再属于任一 λ 的特征向量了)

故 symmetric matrix 可对角化
的证明化为其他 λ , 几何重数 = 代数重数

当 LDL^T 靠近 0 时, 即 $3 \rightarrow 2 \rightarrow 1 \rightarrow 0$ 时, LDL^T 的特征值从 -1 开始到 4, -2 到 1, -8 (即 pivots)。

$$A = LDL^T \quad A = LDL^T$$

λ	4, -2	1, -8
Pivots	1, -8	1, -8

在过程中, eigenvalue 是值变了, 但符号不变 (因为符号变了, 则必是正或负 $\lambda = 1$, $\det A = 0$, 所以从 LDL^T 上看是不可解的)

那对称矩阵 主对角线外的元素 $\rightarrow 0$ 的过程中, 符号不变, 且符号与 pivots 的符号相同

证明:

1. 正定阵的 pivots 都是正的. 即 $A = LDL^T$, D 的元素都是正

~~证明了正定阵的 pivots 都是正的. $x^T A x > 0$ 且 A 是 symmetric eigenvectors for all nonzero vector x~~

~~证: $AX = \lambda X$~~

~~$x^T A x = \lambda x^T x > 0$ 且 $x^T x > 0$ 故 $\lambda > 0$~~

~~证毕!~~

~~$x^T A x = [x \ y] \begin{bmatrix} a & b \\ b & c \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = ax^2 + 2bxy + cy^2 > 0$~~

正定阵的根, 根

定理 4. 1) 根据定理 1, 正定阵 $\det A > 0$, 必是 nonsingular

2) 其逆阵 $A^{-1} = (Q \Lambda Q^T)^{-1} = Q \Lambda^{-1} Q^T$ ($Q^T Q = I$)

若 $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ 则 $\Lambda^{-1} = \text{diag}(\frac{1}{\lambda_1}, \dots, \frac{1}{\lambda_n})$

故 A^{-1} 也为正定阵

定义:

$$A^{\frac{1}{2}} = \sum_{i=1}^n \sqrt{\lambda_i} e_i e_i^T = Q \Lambda^{\frac{1}{2}} Q^T, \text{ 也是正定阵}$$

由根号幂性质, $A^{\frac{1}{2}} A^{\frac{1}{2}} = A$

性质: $(A^{\frac{1}{2}})^{-1} = A^{-\frac{1}{2}} Q^T, \quad \Lambda^{-\frac{1}{2}} = \text{diag}(\frac{1}{\sqrt{\lambda_1}}, \dots, \frac{1}{\sqrt{\lambda_n}})$

写成 $A^{-\frac{1}{2}}$

$$A^{\frac{1}{2}} A^{-\frac{1}{2}} = A^{-\frac{1}{2}} A^{\frac{1}{2}} = I$$

$$A^{-\frac{1}{2}} A^{-\frac{1}{2}} = A^{-1}$$

① Rank不变的理由, $B = M^{-1}AM$ ~~即~~ M^{-1} 与 M 都是可逆的
引理: 任意矩阵与可逆阵相乘不改变秩

即: 若 P, Q 可逆, 则 $r(A) = r(PA) = r(AQ)$

证明: 可逆阵可表示成初等矩阵之乘积

$[A \ I] \xrightarrow[\text{行变换}]{\text{初等变换}} [I \ A^{-1}]$, 即

$(E_1 \cdots E_k E_l)PA = I$, 即可逆阵 $\xrightarrow[\text{变换}]{\text{初等变换}} I$

$A = P^{-1}LI$, 记号

的可逆阵乘积即为 A 与一系列 $\left\{ \begin{array}{l} \text{permutation matrix} \\ \text{elimination matrix} \end{array} \right.$
的乘积, 而初等变换不改变秩

阵的乘积, 不改变 A 的秩 $\left[\text{秩不变} \right]$ (不记)

② $X' = M^{-1}X$ (数量相变, 下面记作 independent)

若 X 满足 $C_1 X_1 + C_2 X_2 = 0$ 只有 $C_1 = C_2 = 0$ 这一种

$$\begin{aligned} \text{则 } C_1 X'_1 + C_2 X'_2 &= C_1 M^{-1} X_1 + C_2 M^{-1} X_2 \\ &= M^{-1} (C_1 X_1 + C_2 X_2) = 0 \end{aligned}$$

由于 M^{-1} 可逆满秩, 故 $C_1 X_1 + C_2 X_2 = 0$, 故 $C_1 = C_2 = 0$

$\therefore M^{-1}X_1$ 与 $M^{-1}X_2$ independent

③ $N(A)$ 仅与 $\lambda=0$ 有关。若 A 有 $\lambda=0$ 则 $N(A)$ 由 $\lambda=0$ 时的
eigenvector 组成

即 $\det A = 0$ 则 A 有特征值 $\lambda=0$, 其特征向量组成 $N(A)$

当然 B 也有 $\lambda=0$, 特征向量 $M^{-1}X$ 组成 $N(B)$

那问题归结为 X 形式为空间与 $M^{-1}X$ 形式为空间是一样吗?

显然不一样 (举个例子的就知悉)

但 $r(N(A))$ 与 $r(N(B))$ 是一样的! 都等于 $n-r$

Singular Value Decomposition (奇异值分解)

定义:

The singular value decomposition (SVD) has orthogonal matrices U and V

$$AV = U\Sigma \quad \text{and then} \quad A = U\Sigma V^{-1} = U\Sigma V^T$$

This is the new factorization of A : orthogonal times diagonal times orthogonal

若 A 为 $m \times n$ 矩阵, 则 V 为 $n \times n$, U 为 $m \times m$

证明: $A^T A$ 为 $n \times n$ 对称矩阵, 它有以下性质

$$A^T A = Q \Lambda Q^{-1}, \quad Q \text{ 为 orthonormal matrix}$$

1) 假设其 eigenvectors 为 v_i , 则

$$A^T A v_i = \lambda_i v_i, \quad v_i^T A^T A v_i = \lambda_i v_i^T v_i = \lambda_i$$

$$\Rightarrow \|A v_i\|^2 = 0, \quad (\text{若 } 0^2 = \lambda_i) \quad \dots \textcircled{1}$$

$$2) A A^T A v_i = \lambda_i A v_i, \quad \text{令 } u_i = \frac{A v_i}{\sqrt{\lambda_i}}, \quad \text{则 } \|u_i\| = 1$$

$$A A^T u_i = \lambda_i u_i, \quad \text{即 } u_i \text{ 是 } \dots \textcircled{2}$$

由此得 u_i 是 $A A^T$ 的特征向量, ~~特征值为~~ 其长度为 1 即.

$A^T A$ 的 orthonormal 特征向量为 v_i , 特征值为 σ_i^2
 $A A^T$ 的 orthonormal 特征向量为 u_i , 特征值为 σ_i^2
 其中 $u_i = A v_i / \sigma_i$


故 $A v_i = \sigma_i u_i$, u_i 有 n 个, v_i 有 m 个 (分别是 $A^T A$, $A A^T$ 的 eigenvectors)

$$\therefore \underset{m \times n}{A} \underset{n \times n}{V} = \underset{m \times m}{U} \underset{m \times n}{\Sigma}$$

(以上证明的是包括了 $\sigma_i = 0$ 的情况)

① 类似 λ , σ 称 singular value
形式

Σ 的形式如下



$A^T A$ 求得的 σ 是实数部分
 $A A^T$ 求得的 σ 是虚数部分
 它们俩 σ (非重复) 的数量
 即为 r !

现在检查 $A^T A$, $A A^T$

$$A^T A v_i = \sigma_i^2 v_i, \text{ 包含两部分 } \begin{cases} A^T A v_i = \sigma_i^2 v_i & (\sigma_i \neq 0) \\ A^T A v_i = 0 & (\sigma_i = 0) \end{cases}$$

对于单位部分, 事实上取 (n) 之前已证明过:

$$N(A) = N(A^T A)$$

$A^T A$ 有 n 个 orthonormal 的特征向量, 但若 A 的秩
 仅为 r ($r < n$), 即 $\text{rank}(A) = 0$ 时, A 有特征值 0 对应
 $n-r$ 个特征向量 $\in N(A)$

→ 与此一致! 满足 $A^T A v_i = 0$

类似地, u 要是 $\in N(A)$ 则 $u \in N(A A^T)$

若 A 有秩为 r , 则 A^T 也为 r , 则 A^T 有特征值 0, 对应的
 $m-r$ 个特征向量 $\in N(A^T)$, 也属于 $N(A A^T)$ 故 $A A^T u_i = 0$
 以上说明左奇异值是实的。

综上, 我们给出 $A v = U \Sigma$ 的另一种非零表示:

$$A = \sum_{i=1}^{r(k)} \sigma_i u_i v_i^T$$

补充 - 是 SVD application

1. Euclidean norm of a matrix

$$\|A\|_2 = \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} = \sigma_{\max} \quad \text{又 称 谱范数}$$

2. Euclidean condition number

$$\text{cond}(A) = \sigma_{\max} / \sigma_{\min}$$

3. 求解线性方程最小二乘问题

$$(\sum_{i=1}^n v_i v_i^T) x = b$$

$$x = \sum_{i=1}^n \frac{v_i^T b}{v_i^T v_i} v_i$$

特别适用于 rank deficient 问题 / ill-condition 问题。因为小 σ 可被抵消

making it less sensitive to the data perturbations in

4. pseudoinverse of a matrix

将 A 的 σ 定义为 σ_i ， σ_i 从大到小

将 A 的其它部分转置

$$A^+ = V \Sigma^+ U^T$$

列满秩的情况 $(A^T A)^+ A^T$ ，与它取

$$\text{即得 } x = (A^T A)^+ A^T b = V \Sigma^+ U^T b$$

性质：

$$(A^+)^+ = A$$

$$A A^+ A = A$$

$$(A A^+)^T = A A^+$$

$$(A^+ A)^T = A^+ A$$

Moore-Penrose conditions