

接著我們探討 singular value 以及 singular vector 的性質。考慮  $A \in M_{m \times n}(\mathbb{R})$  且  $\text{rank}(A) = r$ 。假設  $A = U\Sigma V^t$ ，其中  $U \in M_{m \times m}(\mathbb{R})$ ,  $V \in M_{n \times n}(\mathbb{R})$  皆為 orthogonal matrix (即  $U^{-1} = U^t$  且  $V^{-1} = V^t$ ) 而  $\Sigma \in M_{m \times n}(\mathbb{R})$  是  $(i, i)$ -th entry 為  $\sigma_i$  其餘 entry 為 0 的  $m \times n$  矩陣。則

$$A^t A = (U\Sigma V^t)^t (U\Sigma V) = (V\Sigma^t U^t)(U\Sigma V) = V(\Sigma^t \Sigma)V^t \quad (8.14)$$

注意  $\Sigma^t \Sigma \in M_{n \times n}(\mathbb{R})$  為對角線  $(i, i)$ -th entry 為  $\sigma_i^2$  的對角矩陣。所以式子 (8.14) 就是將  $A^t A$  做正交對角化。由於  $A^t A$  的 eigenvalue  $\lambda_i$  是可以唯一確定的，所以  $\sigma_i = \sqrt{\lambda_i}$  也可唯一確定。也因此若限定  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$ ，則矩陣  $\Sigma$  是唯一的。另一方面，若令矩陣  $V$  的  $i$ -th column 為  $\mathbf{v}_i$ ，則  $\mathbf{v}_1, \dots, \mathbf{v}_n$  為以  $A^t A$  的 eigenvectors 所形成的  $\mathbb{R}^n$  之一組 orthonormal basis。同理考慮  $AA^t$ ，我們有  $AA^t = U(\Sigma\Sigma^t)U^t$ ，因為  $\Sigma\Sigma^t$  為  $m \times m$  的對角矩陣，故若令矩陣  $U$  的  $i$ -th column 為  $\mathbf{u}_i$ ，則  $\mathbf{u}_1, \dots, \mathbf{u}_m$  為以  $AA^t$  的 eigenvectors 所形成的  $\mathbb{R}^m$  之一組 orthonormal basis。

注意，因為  $\text{rank}(A) = \text{rank}(A^t A) = \text{rank}(AA^t) = r$ ，從  $\Sigma^t \Sigma$  和  $\Sigma\Sigma^t$  的對角線來看可知：若將  $A^t A$  和  $AA^t$  eigenvalue 從大排到小，它們前  $r$  個非零的 eigenvalue 會相同而  $A^t A$  和  $AA^t$  後面分別有  $n-r$ 、 $m-r$  個 eigenvalue 為 0。也因此  $A$  和  $A^t$  有相同的非零的 singular value，其餘分別有  $n-r$  和  $m-r$  個 singular value 為 0。

接著我們看 singular vectors。依 singular value 從大到小的順序，當  $1 \leq i \leq r$ ，由  $(A^t A)\mathbf{v}_i = \sigma_i^2 \mathbf{v}_i$ ，知  $\mathbf{v}_i \in \text{Col}(A^t) = \text{Row}(A)$ 。因此由  $\dim(\text{Row}(A)) = r$ ，得  $\mathbf{v}_1, \dots, \mathbf{v}_r$  為  $\text{Row}(A)$  的一組 orthonormal basis。又當  $r+1 \leq i \leq n$ ， $A(\mathbf{v}_i) = \mathbf{0}$ ，故  $\mathbf{v}_{r+1}, \dots, \mathbf{v}_n$  為  $N(A)$  的一組 orthonormal basis (驗證了  $N(A)^\perp = \text{Col}(A^t) = \text{Row}(A)$ )。同理  $\mathbf{u}_1, \dots, \mathbf{u}_r$  是  $\text{Col}(A)$  的一組 orthonormal basis 且  $\mathbf{u}_{r+1}, \dots, \mathbf{u}_m$  為  $N(A^t)$  的一組 orthonormal basis (驗證了  $N(A^t)^\perp = \text{Col}(A)$ )。另一方面，若  $A = U\Sigma V^t$  為  $A$  的 svd，則  $A^t = V\Sigma^t U^t$  就會是  $A^t$  的 svd。所以  $A$  的 right singular vector 就會是  $A^t$  的 left singular vector；反之亦然。

回顧在談論矩陣乘法時，我們介紹了矩陣乘法四種看法 (參見 Section 2.4)。前面 singular value decomposition 的性質完全建立於矩陣乘法的結合律以及 inner product、column、row 這三種乘法的看法。而 svd 的應用，就在於第四種即 outer product 的看法。由於  $A$  的 svd 可寫成

$$A = U\Sigma V^t = \begin{bmatrix} | & & | \\ \mathbf{u}_1 & \cdots & \mathbf{u}_m \\ | & & | \end{bmatrix} \left[ \begin{array}{ccc|ccc} \sigma_1 & & & & & \\ & \ddots & & & & \\ & & \sigma_r & & & \\ \hline & & & \mathbf{0} & & \\ \mathbf{0} & & & & \mathbf{0} & \end{array} \right] \begin{bmatrix} -\mathbf{v}_1- \\ \vdots \\ -\mathbf{v}_n- \end{bmatrix}$$

因此利用 outer product (參見式子 (2.19)) 可得

$$A = \sigma_1 \mathbf{u}_1 \mathbf{v}_1^t + \cdots + \sigma_r \mathbf{u}_r \mathbf{v}_r^t.$$

當我們將資料的訊息存成矩陣  $A$  時，就可由  $A$  的 singular value decomposition 依上式中  $\sigma_i$  的大小做資料的壓縮、修正或辨識等。

Singular Value Decomposition 對於一般 inner product space 之間的 linear transformation 也有相對應的版本。不過我們只談論  $\mathbb{R}^n$ ,  $\mathbb{R}^m$  上的 dot product，所以只考慮  $\mathbb{R}^n$  到  $\mathbb{R}^m$

的 linear transformation。利用 linear transformation 給定定義域與對應域的 ordered basis 後所得的表現矩陣的方法，我們有以下的結論。

**Proposition 8.4.2.** 令  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為 linear transformation 且假設  $\dim(\mathcal{R}(T)) = r$ 。則在  $\mathbb{R}^n$  與  $\mathbb{R}^m$  上分別存在由其 orthonormal basis 所形成的 ordered basis  $\beta, \gamma$  使得  $T$  的表現矩陣為

$$[T]_{\beta}^{\gamma} = \left[ \begin{array}{ccc|ccc} \sigma_1 & & & & & \\ & \ddots & & & & \\ & & \sigma_r & & & \\ \hline & & & \mathbf{0} & & \\ & & & & \mathbf{0} & \end{array} \right] \in M_{m \times n}(\mathbb{R}).$$

Proposition 8.4.2 對於 linear transformation 以及矩陣其所謂 *pseudo-inverse* 的概念相當重要。我們先談 linear transformation 的情況。

令  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為 linear transformation 且假設  $\text{rank}(T) = r$  (即  $T$  的 image  $\mathcal{R}(T)$  的維度  $\dim(\mathcal{R}(T)) = r$ ) 令  $\mathbf{v}_1, \dots, \mathbf{v}_r, \dots, \mathbf{v}_n$  是一組由  $T$  的 right singular vectors 所形成  $\mathbb{R}^n$  上的 orthonormal basis，其中 singular values 滿足  $\sigma_1 \geq \dots \geq \sigma_r > 0$  以及  $\sigma_{r+1} = \dots = \sigma_n = 0$ 。且令  $\mathbf{u}_1, \dots, \mathbf{u}_r, \dots, \mathbf{u}_m$  是所對應的 left singular vectors 所形成  $\mathbb{R}^m$  上的 orthonormal basis。依此設定， $\mathbf{v}_{r+1}, \dots, \mathbf{v}_n$  為  $T$  的 null space  $\mathcal{N}(T)$  的一組 orthonormal basis 且  $\mathbf{v}_1, \dots, \mathbf{v}_r$  為  $\mathcal{N}(T)^\perp$  的一組 orthonormal basis。另一方面  $\mathbf{u}_1, \dots, \mathbf{u}_r$  為  $T$  的 image  $\mathcal{R}(T)$  的一組 orthonormal basis 且  $\mathbf{u}_{r+1}, \dots, \mathbf{u}_m$  為  $\mathcal{R}(T)^\perp$  的一組 orthonormal basis。依此設定，若將  $T$  限制在  $\mathcal{N}(T)^\perp = \text{Span}(\mathbf{v}_1, \dots, \mathbf{v}_r)$  之下，考慮  $T|_{\mathcal{N}(T)^\perp}: \mathcal{N}(T)^\perp \rightarrow \mathcal{R}(T)$ ，則  $T|_{\mathcal{N}(T)^\perp}$  為 isomorphism (即一對一且映成的線性映射)。而  $T|_{\mathcal{N}(T)^\perp}$  的反函數  $T|_{\mathcal{N}(T)^\perp}^{-1}$  滿足

$$T|_{\mathcal{N}(T)^\perp}^{-1}(\mathbf{u}_i) = \frac{1}{\sigma_i} \mathbf{v}_i, \quad \forall i = 1, \dots, r.$$

由於一個 linear transformation 可以由定義域的一組基底所決定 (參見 Theorem 6.1.8)，所以利用  $\mathbf{u}_1, \dots, \mathbf{u}_m$  為  $\mathbb{R}^m$  的一組基底，我們定義  $T^\dagger: \mathbb{R}^m \rightarrow \mathbb{R}^n$  為滿足

$$T^\dagger(\mathbf{u}_i) = \begin{cases} \frac{1}{\sigma_i} \mathbf{v}_i, & 1 \leq i \leq r; \\ \mathbf{0}, & r+1 \leq i \leq m \end{cases}$$

的 linear transformation，並稱  $T^\dagger$  為  $T$  的 *pseudo-inverse*。

為方便說明，我們將  $T$  和  $T^\dagger$  之間關係顯示如下：

$$\begin{array}{ccc|ccc} \mathbb{R}^n & \xrightarrow{T} & \mathbb{R}^m & & \mathbb{R}^m & \xrightarrow{T^\dagger} & \mathbb{R}^n \\ \mathcal{N}(T)^\perp \left\{ \begin{array}{l} \mathbf{v}_1 \\ \vdots \\ \mathbf{v}_r \end{array} \right\} & \mapsto & \left. \begin{array}{l} \sigma_1 \mathbf{u}_1 \\ \vdots \\ \sigma_r \mathbf{u}_r \end{array} \right\} & \mathcal{R}(T) & \left\{ \begin{array}{l} \mathbf{u}_1 \\ \vdots \\ \mathbf{u}_r \end{array} \right\} & \mapsto & \left. \begin{array}{l} \frac{1}{\sigma_1} \mathbf{v}_1 \\ \vdots \\ \frac{1}{\sigma_r} \mathbf{v}_r \end{array} \right\} & \mathcal{N}(T)^\perp \\ \mathcal{N}(T) \left\{ \begin{array}{l} \mathbf{v}_{r+1} \\ \vdots \\ \mathbf{v}_n \end{array} \right\} & \mapsto & \mathbf{0} & \mathcal{R}(T)^\perp & \left\{ \begin{array}{l} \mathbf{u}_{r+1} \\ \vdots \\ \mathbf{u}_m \end{array} \right\} & \mapsto & \mathbf{0} \end{array}$$

注意，從這裡可看出，雖然  $T$  的 singular vectors 並不唯一，但  $N(T)$ ,  $R(T)$  是由  $T$  決定的，所以由  $T^\dagger$  滿足  $T^\dagger|_{R(T)} = T|_{N(T)^\perp}^{-1}$  以及  $T^\dagger|_{R(T)^\perp}$  為零函數，知  $T^\dagger$  是由  $T$  唯一確定的。

由上面  $T$ ,  $T^\dagger$  的關係，我們也很容易了解  $T^\dagger \circ T: \mathbb{R}^n \rightarrow \mathbb{R}^n$  這個 linear operator。因為  $N(T)^\perp$  的基底  $\mathbf{v}_1, \dots, \mathbf{v}_r$  中任一向量  $\mathbf{v}_i$  皆滿足  $T^\dagger \circ T(\mathbf{v}_i) = \mathbf{v}_i$ ，所以  $T^\dagger \circ T(\mathbf{v}) = \mathbf{v}$ ,  $\forall \mathbf{v} \in N(T)^\perp$ 。另一方面，因為  $N(T)$  的基底  $\mathbf{v}_{r+1}, \dots, \mathbf{v}_n$  中任一向量  $\mathbf{v}_i$  皆滿足  $T^\dagger \circ T(\mathbf{v}_i) = \mathbf{0}$ ，所以  $T^\dagger \circ T(\mathbf{v}) = \mathbf{0}$ ,  $\forall \mathbf{v} \in N(T)$ 。也就是說  $T^\dagger \circ T: \mathbb{R}^n \rightarrow \mathbb{R}^n$  滿足

$$T^\dagger \circ T(\mathbf{v}) = \begin{cases} \mathbf{v}, & \forall \mathbf{v} \in N(T)^\perp; \\ \mathbf{0}, & \forall \mathbf{v} \in N(T) = (N(T)^\perp)^\perp \end{cases}$$

因此知  $T^\dagger \circ T: \mathbb{R}^n \rightarrow \mathbb{R}^n$  是對  $N(T)^\perp$  的投影。同理， $T \circ T^\dagger: \mathbb{R}^m \rightarrow \mathbb{R}^m$  是對  $R(T)$  的投影。我們得到以下結果：

**Theorem 8.4.3.** 令  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為 linear transformation 且  $T^\dagger: \mathbb{R}^m \rightarrow \mathbb{R}^n$  為  $T$  的 pseudo-inverse。則

- $T^\dagger \circ T: \mathbb{R}^n \rightarrow \mathbb{R}^n$  是對  $N(T)^\perp$  的 orthogonal projection.
- $T \circ T^\dagger: \mathbb{R}^m \rightarrow \mathbb{R}^m$  是對  $R(T)$  的 orthogonal projection.

特別的，當  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為一對一，即  $N(T) = \{\mathbf{0}\}$ ，此時  $N(T)^\perp = \mathbb{R}^n$ ，所以  $T^\dagger \circ T = \text{id}_{\mathbb{R}^n}$ ；而當  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為映成，即  $R(T) = \mathbb{R}^m$ ，故知  $T \circ T^\dagger = \text{id}_{\mathbb{R}^m}$ 。而當  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  為 isomorphism（此時  $m = n$ ），由於  $T^\dagger \circ T = T \circ T^\dagger = \text{id}_{\mathbb{R}^n}$ ，故知  $T^\dagger$  為  $T$  的 inverse  $T^{-1}$ 。所以我們可以說 pseudo-inverse 是反函數的推廣，使其適用於一般的 linear transformation。

接下來，我們將  $m \times n$  矩陣視為  $\mathbb{R}^n$  映射到  $\mathbb{R}^m$  的 linear transformation，探討矩陣  $A \in M_{m \times n}(\mathbb{R})$  的 pseudo-inverse。前面已知，對於 linear transformation  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$ ，若  $\text{rank}(T) = r$  且  $\beta, \gamma$  分別為  $\mathbb{R}^n, \mathbb{R}^m$  上 orthonormal ordered basis 使得

$$[T]_\beta^\gamma = \left[ \begin{array}{ccc|c} \sigma_1 & & & \mathbf{0} \\ & \ddots & & \\ & & \sigma_r & \\ \hline & & \mathbf{0} & \mathbf{0} \end{array} \right] \in M_{m \times n}(\mathbb{R}),$$

則  $T^\dagger: \mathbb{R}^m \rightarrow \mathbb{R}^n$  的表現矩陣為

$$[T^\dagger]_\gamma^\beta = \left[ \begin{array}{ccc|c} \frac{1}{\sigma_1} & & & \mathbf{0} \\ & \ddots & & \\ & & \frac{1}{\sigma_r} & \\ \hline & & \mathbf{0} & \mathbf{0} \end{array} \right] \in M_{n \times m}(\mathbb{R}).$$

因此若  $A = U\Sigma V^t$  為  $A \in M_{m \times n}(\mathbb{R})$  的 svd 其中  $\sigma_1, \dots, \sigma_r > 0$  且  $\sigma_{r+1} = \dots = \sigma_n = 0$ ，則令  $\Sigma^\dagger$  為  $n \times m$  矩陣，其中當  $1 \leq i \leq r$  時  $\Sigma^\dagger$  的  $(i, i)$ -th entry 為  $\frac{1}{\sigma_i}$ ，而其餘 entry 為 0。也就

是說  $\Sigma$  和  $\Sigma^\dagger$  的關係如下：

$$\Sigma = \left[ \begin{array}{ccc|c} \sigma_1 & & & \mathbf{0} \\ & \ddots & & \\ & & \sigma_r & \\ \hline \mathbf{0} & & & \mathbf{0} \end{array} \right] \in M_{m \times n}(\mathbb{R}), \quad \Sigma^\dagger = \left[ \begin{array}{ccc|c} \frac{1}{\sigma_1} & & & \mathbf{0} \\ & \ddots & & \\ & & \frac{1}{\sigma_r} & \\ \hline \mathbf{0} & & & \mathbf{0} \end{array} \right] \in M_{n \times m}(\mathbb{R}).$$

決定了  $\Sigma^\dagger$  後，我們定義  $A$  的 pseudo-inverse  $A^\dagger \in M_{n \times m}(\mathbb{R})$  為

$$A^\dagger = V\Sigma^\dagger U^t.$$

注意，前面提及一個 linear transformation 的 pseudo-inverse 是唯一的，所以雖然一個矩陣的 svd 並不唯一，但其 pseudo-inverse 是唯一的。

我們看 Example 8.4.1 中各矩陣的 pseudo-inverse.

**Example 8.4.4.** (1)  $A_1 = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$ ，已知  $A_1 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$  為  $A_1$  的 svd。因為  $\Sigma = \Sigma^\dagger$ ，可得

$$A_1^\dagger = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}^t \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}^t = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}$$

我們選在 Example 8.4.1 中  $A_1$  另一個 svd，即  $A_1 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$ 。計算其 pseudo-inverse 依然為

$$A_1^\dagger = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}^t \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}^t = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}.$$

(2)  $A_2 = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$  有一個 svd 為  $A_2 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ ，故得

$$A_2^\dagger = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}^t \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}^t = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}.$$

注意： $A_2$  為 invertible，所以其 pseudo-inverse 就是其 inverse，亦即  $A^\dagger = A^{-1}$ 。另外這裡  $A_1, A_2$  非 0 的 singular value 只有 1，所以  $\Sigma^\dagger = \Sigma^t$ 。在此情況之下若  $A$  的 svd 為  $A = U\Sigma V^t$ ，則  $A^\dagger = V\Sigma^\dagger U^t = (V^t)^t \Sigma^t U^t = A^t$ 。所以  $A_1, A_2$  的 pseudo-inverse 都恰為其轉置矩陣。

(3)  $A_3 = \begin{bmatrix} 0 & 1 \\ 0 & 1 \end{bmatrix}$  有一個 svd 為  $A_3 = \begin{bmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{2} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ ，故得

$$A_3^\dagger = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}^t \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix}^t = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix}.$$

(4)  $A_4 = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}$  有一個 svd 為  $A_4 = \begin{bmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} 3 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix}$ ，故得

$$A_4^\dagger = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix}^t \begin{bmatrix} \frac{1}{3} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix}^t = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{3} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} -\frac{1}{3} & \frac{2}{3} \\ \frac{2}{3} & -\frac{1}{3} \end{bmatrix}.$$

同樣的，因為  $A_4$  為可逆矩陣，故  $A_4^\dagger = A_4^{-1}$ 。

$$(5) B = \begin{bmatrix} 1 & 1 \\ 1 & -1 \\ 1 & 1 \end{bmatrix} \text{ 有一個 svd 為 } B = \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 & \frac{1}{\sqrt{2}} \\ 0 & 1 & 0 \\ \frac{1}{\sqrt{2}} & 0 & -\frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} 2 & 0 \\ 0 & \sqrt{2} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix}, \text{ 故得}$$

$$B^\dagger = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{2} & 0 & 0 \\ 0 & \frac{1}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 & \frac{1}{\sqrt{2}} \\ 0 & 1 & 0 \\ \frac{1}{\sqrt{2}} & 0 & -\frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & -\frac{1}{2} & \frac{1}{4} \end{bmatrix}.$$

注意，因為  $\text{rank}(B) = 2$ ，我們有  $B^\dagger B = I_2$ 。  $\#$

回顧一下，當給定  $A \in M_{m \times n}(\mathbb{R})$ ，我們可以將之視為線性映射  $T: \mathbb{R}^n \rightarrow \mathbb{R}^m$  其中  $T(\mathbf{v}) = A\mathbf{v}, \forall \mathbf{v} \in \mathbb{R}^n$ 。此時  $\text{Col}(A) = \text{R}(T)$  且  $\text{N}(A) = \text{N}(T)$ ，又因  $\text{N}(A)^\perp = \text{Col}(A^\dagger) = \text{Row}(A)$ ，我們將  $A$  和  $A^\dagger$  之間關係顯示如下：

$$\begin{array}{ccc|ccc} \mathbb{R}^n & \xrightarrow{A} & \mathbb{R}^m & & \mathbb{R}^m & \xrightarrow{A^\dagger} & \mathbb{R}^n \\ \text{Row}(A) \left\{ \begin{array}{l} \mathbf{v}_1 \\ \vdots \\ \mathbf{v}_r \end{array} \right\} & \mapsto & \left\{ \begin{array}{l} \sigma_1 \mathbf{u}_1 \\ \vdots \\ \sigma_r \mathbf{u}_r \end{array} \right\} & \text{Col}(A) & \text{Col}(A) \left\{ \begin{array}{l} \mathbf{u}_1 \\ \vdots \\ \mathbf{u}_r \end{array} \right\} & \mapsto & \left\{ \begin{array}{l} \frac{1}{\sigma_1} \mathbf{v}_1 \\ \vdots \\ \frac{1}{\sigma_r} \mathbf{v}_r \end{array} \right\} & \text{Row}(A) \\ \text{N}(A) \left\{ \begin{array}{l} \mathbf{v}_{r+1} \\ \vdots \\ \mathbf{v}_n \end{array} \right\} & \mapsto & \mathbf{0} & & \text{Col}(A)^\perp \left\{ \begin{array}{l} \mathbf{u}_{r+1} \\ \vdots \\ \mathbf{u}_m \end{array} \right\} & \mapsto & \mathbf{0} & \end{array}$$

同樣的，由於  $\text{Row}(A)^\perp = \text{N}(A)$  我們有以下有關 Theorem 8.4.3 的矩陣版本：

**Theorem 8.4.5.** 設  $A \in M_{m \times n}(\mathbb{R})$  且  $A^\dagger \in M_{n \times m}$  為  $A$  的 *pseudo-inverse*。則

- $A^\dagger A \in M_{n \times n}(\mathbb{R})$  是對  $\text{Row}(A)$  的投影矩陣。
- $AA^\dagger \in M_{m \times m}(\mathbb{R})$  是對  $\text{Col}(A)$  的投影矩陣。

特別的，當  $A \in M_{m \times n}(\mathbb{R})$  且  $\text{rank}(A) = n$ ，此時  $\text{Row}(A) = \mathbb{R}^n$ ，所以  $A^\dagger A = I_n$ （參見 Theorem 2.5.5）；而當  $\text{rank}(A) = m$ ，即  $\text{Col}(A) = \mathbb{R}^m$ ，可得  $AA^\dagger = I_m$ （參見 Theorem 2.5.2）。又當  $A$  為可逆矩陣（此時  $n = m$  且  $\text{rank}(A) = n$ ），由於  $A^\dagger A = AA^\dagger = I_n$ ，故知  $A^\dagger$  為  $A$  的反矩陣  $A^{-1}$ （參見 Theorem 2.6.2）。所以我們可以說 pseudo-inverse 是反矩陣的推廣，使其適用於一般的矩陣。

Theorem 8.4.5 最主要的應用就是幫助我們處理聯立方程組  $A\mathbf{x} = \mathbf{b}$ 。回顧一下，當聯立方程組的係數矩陣  $A$  為可逆矩陣，則方程組  $A\mathbf{x} = \mathbf{b}$  一定有解且有唯一的一組解  $\mathbf{x} = A^{-1}\mathbf{b}$ 。而當  $A$  不是可逆，那  $\mathbf{x} = A^\dagger \mathbf{b}$  和聯立方程組  $A\mathbf{x} = \mathbf{b}$  的解有何關係呢？我們分成兩種情況討論：

**$A\mathbf{x} = \mathbf{b}$  有解。** 此時  $\mathbf{b} \in \text{Col}(A)$ （參見 Lemma 2.5.1），又因  $AA^\dagger$  為對  $\text{Col}(A)$  的投影，所以若將  $\mathbf{x} = A^\dagger \mathbf{b}$  代入  $A\mathbf{x}$  會得  $A\mathbf{x} = A(A^\dagger \mathbf{b}) = (AA^\dagger)\mathbf{b} = \mathbf{b}$ 。也就是說  $\mathbf{x} = A^\dagger \mathbf{b}$  為  $A\mathbf{x} = \mathbf{b}$  的一組解。然而若  $A\mathbf{x} = \mathbf{b}$  有無窮多組解，那  $\mathbf{x} = A^\dagger \mathbf{b}$  這組解有何特殊意義呢？回顧一下，當聯立方程組  $A\mathbf{x} = \mathbf{b}$  有無窮多組解時，其中一定有唯一的一組解是在  $\text{Row}(A)$  中，且這組解是所

有解中長度最短的一組解，稱之為  $A\mathbf{x} = \mathbf{b}$  的 minimal solution (參見 Corollary 4.5.8)。而在前面  $A, A^\dagger$  的討論中，我們知道  $A^\dagger \mathbf{b} \in \text{Row}(A)$ ，所以  $\mathbf{x} = A^\dagger \mathbf{b}$  就是聯立方程組  $A\mathbf{x} = \mathbf{b}$  在  $\text{Row}(A)$  中唯一的那組解，也就是說  $\mathbf{x} = A^\dagger \mathbf{b}$  是  $A\mathbf{x} = \mathbf{b}$  的 minimal solution. 事實上，當  $\mathbf{x}_0$  為  $A\mathbf{x} = \mathbf{b}$  的一組解時，將  $\mathbf{x}_0$  投影到  $\text{Row}(A)$ ，得  $(A^\dagger A)\mathbf{x}_0 = A^\dagger(A\mathbf{x}_0) = A^\dagger \mathbf{b}$ ，就是  $A\mathbf{x} = \mathbf{b}$  的 minimal solution。

**$A\mathbf{x} = \mathbf{b}$  無解.** 此時  $\mathbf{b} \notin \text{Col}(A)$ ，所以我們要在  $\text{Col}(A)$  中找到一個距離  $\mathbf{b}$  最近的向量  $\mathbf{b}_0$ ，此時  $A\mathbf{x} = \mathbf{b}_0$  有解，且其解稱為方程組  $A\mathbf{x} = \mathbf{b}$  的 least squares solution。向量  $\mathbf{b}_0$  事實上是  $\mathbf{b}$  在  $\text{Col}(A)$  的投影 (參見 Proposition 4.3.15)，即  $\mathbf{b}_0 = (AA^\dagger)\mathbf{b} = A(A^\dagger \mathbf{b})$ 。也就是說  $\mathbf{x} = A^\dagger \mathbf{b}$  是  $A\mathbf{x} = \mathbf{b}_0$  的一組解，因此也就是  $A\mathbf{x} = \mathbf{b}$  的一組 least squares solution. 而若  $A\mathbf{x} = \mathbf{b}$  有無窮多的 least squares solution，即  $A\mathbf{x} = \mathbf{b}_0$  有無窮多解，此時由前面的討論我們知  $\mathbf{x} = A^\dagger \mathbf{b}$  是所有解中長度最短的，所以它就是  $A\mathbf{x} = \mathbf{b}$  的 minimal least squares solution。

**Example 8.4.6.** (1) 考慮聯立方程組

$$(a) \quad \begin{cases} x + y = 1 \\ x - y = 2 \\ x + y = 1 \end{cases}; \quad (b) \quad \begin{cases} x + y = 1 \\ x - y = 2 \\ x + y = 2 \end{cases}$$

為了方便起見我們分別用  $A\mathbf{x} = \mathbf{b}_1$ ,  $A\mathbf{x} = \mathbf{b}_2$  表示方程組 (a), (b). 很容易看出 (a) 有解但 (b) 無解。事實上若用合併的增廣矩陣  $[A|\mathbf{b}_1 \mathbf{b}_2]$  將係數矩陣  $A$  化為 echelon form，即

$$\left[ \begin{array}{cc|cc} 1 & 1 & 1 & 1 \\ 1 & -1 & 2 & 2 \\ 1 & 1 & 1 & 2 \end{array} \right] \rightsquigarrow \left[ \begin{array}{cc|cc} 1 & 1 & 1 & 1 \\ 0 & -2 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{array} \right]$$

可知 (a) 有唯一解  $\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} \frac{3}{2} \\ -\frac{1}{2} \end{bmatrix}$ 。而利用 Example

8.4.4 (5) 的結果,  $A^\dagger = \begin{bmatrix} \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & -\frac{1}{2} & \frac{1}{4} \end{bmatrix}$ ，確實  $\begin{bmatrix} x \\ y \end{bmatrix} = A^\dagger \mathbf{b}_1 = \begin{bmatrix} \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & -\frac{1}{2} & \frac{1}{4} \end{bmatrix} \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} = \begin{bmatrix} \frac{3}{2} \\ -\frac{1}{2} \end{bmatrix}$  為  $A\mathbf{x} = \mathbf{b}_1$

的唯一解。至於方程組 (b) 我們可利用其 normal equation  $A^t A \mathbf{x} = A^t \mathbf{b}_2$ ，得到其 least squares solution (參見 Definition 4.5.2)。將 normal equation 的增廣矩陣  $[A^t A | A^t \mathbf{b}_2]$  化為 echelon form，即

$$\left[ \begin{array}{ccc|c} 3 & 1 & 5 \\ 1 & 3 & 1 \end{array} \right] \rightsquigarrow \left[ \begin{array}{ccc|c} 3 & 1 & 5 \\ 0 & \frac{8}{3} & \frac{-2}{3} \end{array} \right]$$

解得  $A\mathbf{x} = \mathbf{b}_2$  的 least squares solution 為  $\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} \frac{7}{4} \\ -\frac{1}{4} \end{bmatrix}$ ，因而  $\begin{bmatrix} x \\ y \end{bmatrix} = A^\dagger \mathbf{b}_2 = \begin{bmatrix} \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & -\frac{1}{2} & \frac{1}{4} \end{bmatrix} \begin{bmatrix} 1 \\ 2 \\ 2 \end{bmatrix} = \begin{bmatrix} \frac{7}{4} \\ -\frac{1}{4} \end{bmatrix}$  確實是方程組 (b) 的 least squares solution.

(2) 考慮聯立方程組

$$(a) \quad \begin{cases} x + y + z = 1 \\ x - y + z = 1 \\ x + z = 1 \end{cases}; \quad (b) \quad \begin{cases} x + y + z = 1 \\ x - y + z = 1 \\ x + z = 2 \end{cases}$$

為了方便起見我們分別用  $A\mathbf{x} = \mathbf{b}_1$ ,  $A\mathbf{x} = \mathbf{b}_2$  表示方程組 (a), (b). 若用合併的增廣矩陣  $[A|\mathbf{b}_1 \mathbf{b}_2]$  將係數矩陣  $A$  化為 echelon form，即

$$\left[ \begin{array}{ccc|cc} 1 & 1 & 1 & 1 & 1 \\ 1 & -1 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 & 2 \end{array} \right] \rightsquigarrow \left[ \begin{array}{ccc|cc} 1 & 1 & 1 & 1 & 1 \\ 0 & -2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{array} \right]$$

可知 (a) 有無窮多解  $\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} 1-t \\ 0 \\ t \end{bmatrix}$  ; 而 (b) 無解。所以我們需找到 (a) 的 minimal solution 以及 (b) 的 minimal least squares solution.

要找到  $A\mathbf{x} = \mathbf{b}_1$  的 minimal solution, 可以先找到  $AA^t\mathbf{x} = \mathbf{b}_1$  的一組解  $\mathbf{x}_0$ , 便可得  $\mathbf{x} = A^t\mathbf{x}_0$  為  $A\mathbf{x} = \mathbf{b}_1$  的 minimal solution (參見 Proposition 4.5.7)。故先將增廣矩陣  $[AA^t|\mathbf{b}_1]$

化為 echelon form, 即  $\left[ \begin{array}{ccc|c} 3 & 1 & 2 & 1 \\ 1 & 3 & 2 & 1 \\ 2 & 2 & 2 & 1 \end{array} \right] \rightsquigarrow \left[ \begin{array}{ccc|c} 3 & 1 & 2 & 1 \\ 0 & \frac{8}{3} & \frac{4}{3} & \frac{2}{3} \\ 0 & 0 & 0 & 0 \end{array} \right]$  得到  $\mathbf{x}_0 = \begin{bmatrix} 0 \\ 0 \\ \frac{1}{2} \end{bmatrix}$  為  $AA^t\mathbf{x} = \mathbf{b}_1$  的

一組解。也因此知  $\mathbf{x} = A^t\mathbf{x}_0 = \begin{bmatrix} \frac{1}{2} \\ 0 \\ \frac{1}{2} \end{bmatrix}$  為方程組 (a) 的 minimal solution. 而利用  $A$  的 svd 可

算出  $A^\dagger = \begin{bmatrix} \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ \frac{1}{2} & \frac{-1}{2} & 0 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{bmatrix}$ , 因而知  $\begin{bmatrix} x \\ y \\ z \end{bmatrix} = A^\dagger\mathbf{b}_1 = \begin{bmatrix} \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ \frac{1}{2} & \frac{-1}{2} & 0 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} \frac{1}{2} \\ 0 \\ \frac{1}{2} \end{bmatrix}$  確實是  $A\mathbf{x} = \mathbf{b}_1$  的 minimal solution。

至於方程組  $A\mathbf{x} = \mathbf{b}_2$ , 由於其 normal equation  $A^tA\mathbf{x} = A^t\mathbf{b}_2$  的解都是 least squares solution。所以套用剛才方法找到 normal equation  $\begin{bmatrix} 3 & 0 & 3 \\ 0 & 2 & 0 \\ 3 & 0 & 3 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} 4 \\ 0 \\ 4 \end{bmatrix}$  的 minimal solution

即可。亦即, 若 normal equation 為  $B\mathbf{x} = \mathbf{b}_0$ , 先找到  $BB^t\mathbf{x} = \mathbf{b}_0$  的一組解, 例如  $\mathbf{x}_0 = \begin{bmatrix} 0 \\ 0 \\ \frac{2}{9} \end{bmatrix}$ ,

就可得 minimal solution  $B^t\mathbf{x}_0 = \begin{bmatrix} \frac{2}{3} \\ 0 \\ \frac{2}{3} \end{bmatrix}$ 。另一方面,  $A^\dagger\mathbf{b}_2 = \begin{bmatrix} \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ \frac{1}{2} & \frac{-1}{2} & 0 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 2 \end{bmatrix} = \begin{bmatrix} \frac{2}{3} \\ 0 \\ \frac{2}{3} \end{bmatrix}$  確實是方程組 (b) 的 minimal least squares solution. ‡

**Exercise 8.21.** 請直接利用 Exercise 8.16 關於以下矩陣的 svd 處理。

$$C = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \quad C' = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 0 & -2 & 1 \\ 1 & -1 & 1 & 1 \end{bmatrix}$$

- (1) 將矩陣  $C$  寫成 rank 1 的矩陣 (principle component) 之和。
- (2) 分別寫下  $C, C'$  的 pseudo-inverse.
- (3) 考慮聯立方程組

$$(a) \begin{cases} x_1 + x_2 + x_3 + x_4 = 2 \\ x_1 - 2x_3 + x_4 = -1 \\ x_1 - x_2 + x_3 + x_4 = 2 \end{cases}; \quad (b) \begin{cases} x_1 + x_2 + x_3 = 1 \\ x_1 - x_3 = 0 \\ x_1 - x_2 + x_3 = 1 \\ x_1 + x_2 + x_3 = 2 \end{cases}$$

若有解請寫下所有的解，並利用 pseudo-inverse 求得其 minimal solution；若無解，請寫下其 normal equation。求其解並驗證是否與利用 pseudo-inverse 求得的 least squares solution 一致。

**Exercise 8.22.** 考慮矩陣  $A = \begin{bmatrix} 1 & 0 \end{bmatrix}$ ,  $B = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ 。

- (1) 試求  $A^\dagger$ ,  $B^\dagger$ ,  $(AB)^\dagger$  以及  $(BA)^\dagger$ 。
- (2) 驗證  $(AB)^\dagger = B^\dagger A^\dagger$  以及  $(BA)^\dagger = A^\dagger B^\dagger$  是否成立。

**Exercise 8.23.** 設  $A \in M_{m \times n}(\mathbb{R})$ 。證明以下成立：

- (1)  $(A^\dagger)^\dagger = A$ 。
- (2)  $(A^t)^\dagger = (A^\dagger)^t$ 。
- (3)  $AA^\dagger A = A$  且  $A^\dagger AA^\dagger = A^\dagger$ 。

**Exercise 8.24.** 假設  $A \in M_{m \times n}(\mathbb{R})$ ,  $B \in M_{n \times k}(\mathbb{R})$  且  $\text{rank}(A) = \text{rank}(B) = n$ 。回顧：此時  $A^t A$  以及  $B^t B$  皆為 invertible。

- (1) 證明  $A^\dagger = (A^t A)^{-1} A^t$  且  $B^\dagger = B^t (B B^t)^{-1}$ 。
- (2) 證明  $(AB)^\dagger = B^\dagger A^\dagger$ 。