

拓展资源 4.2 补充内容

霍特林 (Hotelling) 变换是基于图像统计特性的变换, 其变换核可变。不同的随机图像场有不同的变换核, 这种变换可压缩图像数据, 且是在均方误差最小下的最佳逼近。

在获取、传输图像时, 总是混杂有许多随机干扰因素, 因此, 实际得到的图像都含有随机的性质, 称为随机图像。

例如, 一幅图像通过卫星传送了 N 次, 这时由于电波传播的影响, N 幅图像互有差异。

设 $f_i(x, y)$ 表示一个 $N \times N$ 的随机图像 $f(x, y)$ 的第 i 个样本, 为了用线性代数的工具进行讨论, 采用图像的向量形式表示图像。

$$\mathbf{X}_i = \begin{pmatrix} f_i(0,0) \\ f_i(0,1) \\ \vdots \\ f_i(0,N-1) \\ f_i(1,0) \\ \vdots \\ f_i(1,N-1) \\ \vdots \\ f_i(N-1,N-1) \end{pmatrix} \quad \text{按行推叠}$$

\mathbf{X}_i 是 $N^2 \times 1$ 的随机矢量或 N^2 维随机矢量。

1. 随机矢量的均值和协方差

设一组 M 个如下形式表示的随机矢量

为了讨论简单, 假设图像矢量的维数为 N , 而不是 N^2 。

$$\mathbf{X}^k = \underbrace{\begin{bmatrix} x_1^k, x_2^k, \dots, x_N^k \end{bmatrix}^T}_{\text{随机变量}} \quad \underbrace{k=1, 2, \dots, M}_{M \text{ 个样本或 } M \text{ 个图像矢量}}$$

其矢量的均值矢量为

$$\mathbf{m}_x = E\{X\} \approx \frac{1}{M} \sum_{k=1}^M \mathbf{X}_k \quad \leftarrow \text{由 } M \text{ 个样本矢量来估计}$$

协方差矩阵为

$$\begin{aligned} \mathbf{C}_x &= E\left\{(x - \mathbf{m}_x)(x - \mathbf{m}_x)^T\right\} \rightarrow N \times N \text{ 阶矩阵} \\ &\approx \frac{1}{M} \sum_{k=1}^M \mathbf{X}_k \mathbf{X}_k^T - \mathbf{m}_x \mathbf{m}_x^T \rightarrow \text{估计} \end{aligned}$$

\mathbf{C}_x 的元素: 对角元素是各个随机变量的方差, 非对角元素是它们的协方差。

例如, 已知一个随机矢量的 4 个样本为

$$\mathbf{X}_1 = (0, 0, 0)^T, \mathbf{X}_2 = (1, 0, 0)^T, \mathbf{X}_3 = (1, 1, 0)^T, \mathbf{X}_4 = (1, 0, 1)^T$$

$$\begin{aligned}
 \mathbf{m}_x &= \frac{1}{4}(0+1+1+1, 0+0+1+0, 0+0+0+1)^T = \frac{1}{4}(3,1,1)^T = \frac{1}{4} \begin{pmatrix} 3 \\ 1 \\ 1 \end{pmatrix} \\
 \mathbf{C}_x &= \frac{1}{4} \left\{ (0,0,0)^T (0,0,0) + \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} (1,0,0) + \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} (1,1,0) + \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix} (1,0,1) \right\} - \frac{1}{4} \begin{pmatrix} 3 \\ 1 \\ 1 \end{pmatrix} \times \frac{1}{4} (3,1,1) \\
 &= \frac{1}{4} \left\{ \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} 1 & 0 & 1 \\ 0 & 0 & 0 \\ 1 & 0 & 1 \end{pmatrix} \right\} - \frac{1}{16} \begin{pmatrix} 9 & 3 & 3 \\ 3 & 1 & 1 \\ 3 & 1 & 1 \end{pmatrix} \\
 &= \frac{1}{4} \begin{pmatrix} 3 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} - \frac{1}{16} \begin{pmatrix} 9 & 3 & 3 \\ 3 & 1 & 1 \\ 3 & 1 & 1 \end{pmatrix} = \frac{1}{16} \begin{pmatrix} 12 & 4 & 4 \\ 4 & 4 & 0 \\ 4 & 0 & 4 \end{pmatrix} - \frac{1}{16} \begin{pmatrix} 9 & 3 & 3 \\ 3 & 1 & 1 \\ 3 & 1 & 1 \end{pmatrix} \\
 &= \frac{1}{16} \begin{pmatrix} 3 & 1 & 1 \\ 1 & 3 & -1 \\ 1 & -1 & 3 \end{pmatrix}
 \end{aligned}$$

(1) \mathbf{C}_x 的主对角各项相等，表示各随机变量有相同的方差。

(2) $\mathbf{C}_{ij} > 0$ ，表示随机变量 i 与 j 正相关，否则为负相关。

2. 霍特林变换的定义

N 维随机矢量 \mathbf{X} 的 Hotelling 正变换为

$$\mathbf{Y} = \mathbf{A}(\mathbf{x} - \mathbf{m}_x)$$

式中， \mathbf{A} 为变换核矩阵。

反变换为

$$\mathbf{X} = \mathbf{A}^T \mathbf{Y} + \mathbf{m}_x$$

\mathbf{A} 的构成如下。

\mathbf{A} 的各行由 \mathbf{C}_x 的特征矢量组成。

令 \mathbf{e}_i 和 λ_i ($i=1,2,\dots,N$) 分别为 \mathbf{C}_x 的特征矢量和对应的特征值。

$$\mathbf{A} = \begin{pmatrix} \mathbf{e}_{11} & \mathbf{e}_{12} & \mathbf{e}_{13} & \cdots & \mathbf{e}_{1N} \\ \mathbf{e}_2 & & & & \vdots \\ \vdots & & & & \vdots \\ \mathbf{e}_N & \cdots & \cdots & \cdots & \mathbf{e}_{NN} \end{pmatrix} \begin{matrix} \lambda_1 \text{ 为第 1 个特征值对应的特征矢量} \\ \lambda_2 \text{ 为第 2 个特征值对应的特征矢量} \\ \vdots \\ \lambda_N \text{ 为第 } N \text{ 个特征值对应的特征矢量} \end{matrix}$$

λ_i 单调排列： $\lambda_i \geq \lambda_{i+1}$ ($i=1,2,\dots,N-1$)

由定义可知 Hotelling 变换是基于图像统计特性的变换，其变换核可变。不同的随机图像场有不同的 \mathbf{A} 变换核。

例：

$$\mathbf{X}_1 = \begin{pmatrix} 2 \\ 0 \end{pmatrix}, \mathbf{X}_2 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \mathbf{X}_3 = \begin{pmatrix} -1 \\ 3 \end{pmatrix}, \mathbf{X}_4 = \begin{pmatrix} -2 \\ 4 \end{pmatrix}, \mathbf{m}_x = (0,2)^T$$

$$\mathbf{C}_x = \frac{1}{4} \left\{ \begin{pmatrix} 4 & 0 \\ 0 & 0 \end{pmatrix} + \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} + \begin{pmatrix} 1 & -3 \\ -3 & 9 \end{pmatrix} + \begin{pmatrix} 4 & -8 \\ -8 & 16 \end{pmatrix} \right\} - \begin{pmatrix} 0 \\ 2 \end{pmatrix} (0,2)$$

$$= \frac{1}{4} \begin{pmatrix} 10 & -10 \\ -10 & 26 \end{pmatrix} - \begin{pmatrix} 0 & 0 \\ 0 & 4 \end{pmatrix} = \begin{pmatrix} \frac{5}{2} & \frac{-5}{2} \\ \frac{-5}{2} & \frac{5}{2} \end{pmatrix}$$

求 C_x 矩阵的特征值 λ_i

$$|C_x - \lambda_i| = 0 \quad \begin{vmatrix} \frac{5}{2} - \lambda & \frac{-5}{2} \\ \frac{-5}{2} & \frac{5}{2} - \lambda \end{vmatrix} = 0$$

故 $\lambda_1=5, \lambda_2=0$

求 λ_i 对应的特征向量 \mathbf{e}_i

$C_x \mathbf{e}_i = \lambda_i \mathbf{e}_i$, 将 $\lambda_1=5$ 代入

$$(C_x - \lambda_1 I) \mathbf{e}_1 = 0 \quad \begin{pmatrix} \frac{5}{2} - 5 & \frac{-5}{2} \\ \frac{-5}{2} & \frac{5}{2} - 5 \end{pmatrix} \begin{pmatrix} \mathbf{e}_{11} \\ \mathbf{e}_{12} \end{pmatrix} = 0$$

$$\begin{cases} -\mathbf{e}_{11} - \mathbf{e}_{12} = 0 \\ -\mathbf{e}_{11} - \mathbf{e}_{12} = 0 \end{cases} \Rightarrow \mathbf{e}_{11} = -\mathbf{e}_{12} \Rightarrow \begin{pmatrix} \mathbf{e}_{11} \\ \mathbf{e}_{12} \end{pmatrix} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$

将 $\lambda_2=0$ 代入, 得

$$\mathbf{e}_2 = \begin{pmatrix} \mathbf{e}_{21} \\ \mathbf{e}_{22} \end{pmatrix} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} \quad \therefore \mathbf{A} = \frac{1}{2} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix}$$

离散 KL 变换

$$Y_1 = \mathbf{A}(X_1 - \mathbf{m}_x) = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} 2 \\ -2 \end{pmatrix} = \begin{pmatrix} 2\sqrt{2} \\ 0 \end{pmatrix}$$

$$Y_2 = \mathbf{A}(X_2 - \mathbf{m}_x) = \begin{pmatrix} \sqrt{2} \\ 0 \end{pmatrix}$$

$$Y_3 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} -1 \\ 1 \end{pmatrix} = \begin{pmatrix} -\sqrt{2} \\ 0 \end{pmatrix}$$

$$Y_4 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} -2 \\ 2 \end{pmatrix} = \begin{pmatrix} -2\sqrt{2} \\ 0 \end{pmatrix}$$

3. Hotelling 变换的性质

(1) Y 的均值为零

$$\begin{aligned} \mathbf{m}_y &= E\{Y\} = E\{\mathbf{A}(X - \mathbf{m}_x)\} \\ &= \mathbf{A}E\{X\} - \mathbf{A}\mathbf{m}_x = 0 \end{aligned}$$

(2) Y 的协方差为

$$C_y = \begin{pmatrix} \lambda_1 & & & 0 \\ & \lambda_2 & & \\ & & \ddots & \\ 0 & & & \lambda_N \end{pmatrix}$$

$$C_y = E\{(AX - Am_x)(AX - Am_x)^T\}$$

$$= E\{(AX - Am_x)(X - m_x)^T A^T\}$$

$$= AC_x A^T$$

(3) $A^{-1} = A^T$ ∵ A 为对称矩阵

4. Hotelling 变换的好处

用这种变换来压缩图像数据，是在均方误差最小下的最佳逼近。

$$Y' = A_k (X - m_x) \quad K \times 1 \text{ 矩阵}$$

式中， A_k 为取入最大的前 K 个特征向量组成变换核矩阵。

$$A = \begin{pmatrix} \mathbf{e}_{11} & \mathbf{e}_{12} & \cdots & \mathbf{e}_{1N} \\ \mathbf{e}_{21} & \mathbf{e}_{22} & \cdots & \mathbf{e}_{2N} \\ \mathbf{e}_{k1} & \mathbf{e}_{k2} & \cdots & \mathbf{e}_{kN} \\ \mathbf{e}_{N1} & \mathbf{e}_{N2} & \cdots & \mathbf{e}_{NN} \end{pmatrix} \left. \begin{array}{l} \text{前 } K \text{ 个特征向量} \\ \text{后 } N-K \text{ 个特征向量, 其对应入值较小} \end{array} \right\}$$

$$A_k = \begin{pmatrix} \mathbf{e}_{11} & \mathbf{e}_{12} & \cdots & \mathbf{e}_{1N} \\ \vdots & & & \vdots \\ \mathbf{e}_{k1} & \mathbf{e}_{k2} & \cdots & \mathbf{e}_{kN} \end{pmatrix}$$

$$\text{原图像估值} \rightarrow \hat{X} = A_k^T Y'_k + m_x \quad Y'_k = \begin{pmatrix} Y' \\ \vdots \\ 0 \end{pmatrix} N \times 1 \text{ 矩阵}$$

由 \hat{X} 与 X 的均方误差近似为

$$\varepsilon \approx \sum_{i=k+1}^N \lambda_i$$

∵ λ 是按大小排列，

∴ $k+1$ 至 N (N^2) 的 λ_i 是非常小的。