

方法都是基于 L2 范数的，L2 范数与 F 范数一样对异常值敏感(Qifa Ke, Kanade, 2005)。

FPCA 是一种具有统计基础的矩阵分解方法，相较于 2DPCA，FPCA 有一个因子协方差模型，该模型假定数据服从矩阵正态分布，是一种的概率方法(Dryden et al., 2009)。然而，正是因为正态假定使得 FPCA 对非正态特征（如偏态和重尾）缺乏稳定性和稳健性(Lange et al., 1989; Lin et al., 2015)。

RFPCA 是一种新的 FPCA 的稳健扩展方法，从多元 t 分布能够有效处理异常值从而得到稳健估计的特性出发(Lange et al., 1989)，考虑在 FPCA 的基础上，将矩阵正态分布替换为矩阵变元 t 分布(Gupta et al., 2013)，有效提高了 FPCA 的稳健性。但是，当 RFPCA 应用于人脸识别中时，局限于使用人脸的灰度图像，图像的颜色信息完全消失(El-Melegy, Kamal, 2017)。若为了保留图像的颜色信息，将三维数据转换为二维数据，RFPCA 又面临着“维数灾难”问题。

实际上，在判别分析中，小样本、高维度的数据情形有着相似困境，不但计算耗时，而且计算中的估计偏差会导致判别结果有误，基于此，Friedman(1989)提出一种群协方差矩阵正则化方法(Mkhadri et al., 1997)，能够有效提高分类精度，并且能够实现快速计算。该方法通过替换协方差矩阵的极大似然估计得以实现，替换后协方差矩阵的表达式中含有正则化参数，的值是通过最小化交叉验证错分类风险确定的。当使用 Expectation Maximization (EM) 算法(Dempster et al., 1977)进行极大似然估计 (Maximum Likelihood Estimation, ML Estimation) 时，存在矩阵奇异或退化的问题，Fraley 和 Raftery(2007)提议用基于 EM 算法的最大后验估计 (Maximum A Posteriori Estimation, MAP Estimation) 替换 ML 估计，其中涉及一个分散但恰当的共轭先验，是一种基于贝叶斯模型的正则化方法，Mkhadri et al.(1997)将其称为正则化预测判别分析。

很自然地，有学者考虑将正则化方法应用到 PCA 上来，Raiko et al.(2007)尝试在目标函数上添加惩罚项，得到一种正则化 PCA (Regularized PCA)。Zou et al.(2006)提出了一种新的稀疏主成分分析法 (SPCA)，利用 lasso(弹性网) 来生成带有稀疏载荷的修正主成分。通过基于 l_0 及 l_1 惩罚的正则化方法，添加正则化稀疏惩罚项，Sun et al.(2013)得到一种稳健的 2DPCA (robust 2DPCA)，这种稳健 2DPCA 能够在保留空间信息的同时，对异常值不敏感。除此之外，通过一种结构化稀疏正则化方法，即在二维图像中加入结构化稀疏先验，也能达到前者的

效果(Sun et al., 2015)。但是, 这些都是在非概率方法中考察正则化, 在进行人脸图像识别时, 非概率方法无法有效应对不确定性来源, 如光照和姿态变化(Zhao et al., 2003)。

由Dempster et al. (1977)提出的 EM 算法是一种通过迭代方式计算参数极大似然估计的算法, 可应用于有数据缺失的情形。该算法能够确保似然函数在每一步迭代时都处于上升趋势, 且收敛到局部极大值。两种 EM 型算法 Expectation Conditional Maximization (ECM) 算法(Meng, Rubin, 1993) 和 ECM of Either (ECME) 算法(Liu, Rubin, 1994) 是 EM 算法的拓展, 相比于 EM 算法, 这两种算法的收敛速度更快。

第三节 研究内容及创新之处

为了解决 RFPCA 在高维矩阵型数据上进行参数估计时面临的矩阵奇异或退化问题, 本文提出了正则化稳健主成分分析方法 (Regularized Robust PCA, R-RPCA)。与 RFPCA 一样, R-RPCA 使用矩阵变元 t 分布Gupta et al. (2013), 且具有稳健性。本文的创新点包括:

(1) 基于矩阵变元 t 分布, 提出了能够解决 RFPCA 在高维矩阵型数据上所面临的问题的方法 R-RPCA;

(2) R-RPCA 利用最大后验估计 (MAP Estimation) 来进行参数估计, 有效解决了 RFPCA 利用极大似然估计 (ML Estimation) 来进行参数估计时参数在迭代过程中发生矩阵奇异或退化的问题;

(3) 使用 k 折交叉验证选取最优的正则化参数 λ , 以此训练出最优模型, 再通过 EM 型算法, 得到 R-RPCA 的 MAP;

(4) 与基于矩阵正态分布的正则化主成分分析 (Regularized PCA, R-PCA) 相比较, R-RPCA 是稳健的;

(5) 矩阵变元 t 分布中的协方差矩阵分为可分协方差矩阵和不可分协方差矩阵。实验结果表明, 在进行最大后验估计时, 针对可分协方差矩阵, 引入一个正则化参数 λ 表现更好; 针对不可分协方差矩阵, 引入两个正则化参数 λ_1 和 λ_2 表现更优。

第四节 余下章节结构安排

本文余下章节安排如下:

第二章：相关理论与方法。本章简要回顾了文中涉及到的 EM 型算法、矩阵正态分布及其基础上的 FPCA、矩阵变元 t 分布及其基础上的 RFPCA。

第三章：正则化稳健主成分分析。本章引出了正则化稳健主成分分析 (R-RPCA) 方法并对其做了介绍，另外，在引入两种先验信息的情况下分别给出了 R-RPCA 第一种正则化 (MAP1) 和第二种正则化 (MAP2) 的最大后验估计算法。

第四章：实验。本章进行了一系列在模拟数据上的模拟实验以及 R-RPCA 的 MAP1 和 MAP2 在真实数据上的应用。模拟实验包括 ECM 和 ECME 算法的收敛性、两种算法对初始化的敏感性、参数估计的准确性、模型稳健性、异常值检测。真实实验包括人脸识别和多元时间序列的分类。

第五章：总结与展望。本章对本文的主要内容进行了简要的总结，重申了创新之处，并概括了实验结论，同时阐述了后续可能的研究方向。

第二章 相关理论与方法

第一节 EM 及其拓展算法

一、EM 算法

EM 算法(Dempster et al., 1977) 是一种通过迭代方式计算参数极大似然估计的算法, 常用于含有潜变量的概率模型中, 可应用于有数据缺失以及存在潜在(即无法观测) 变量的情形。

记完全数据 $\mathbf{X} = \{\mathbf{X}_o; \mathbf{Z}\}$, 其中 \mathbf{X}_o 为观测数据, \mathbf{Z} 为缺失数据, 则 EM 算法主要分为两步:

E-step: 计算完全数据对数似然函数的条件期望

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) = \mathbb{E}[\mathcal{L}(\boldsymbol{\theta} | \mathbf{X}) | \mathbf{X}_o, \boldsymbol{\theta}^{(t)}] \quad (2.1)$$

M-step: 关于 $\boldsymbol{\theta}$ 极大化 **E-step** 的条件期望, 得到 $\boldsymbol{\theta}$ 的估计值

$$\boldsymbol{\theta}^{(t+1)} = \underset{\boldsymbol{\theta}}{\text{Argmax}} Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) \quad (2.2)$$

循环 **E-step** 和 **M-step** 两个步骤, 当对数似然 \mathcal{L} 的值小于某个给定的取值时, 退出迭代过程。

二、EM 型算法

本节介绍两种 EM 型算法, 即 ECM 算法和 ECME 算法。

• ECM 算法由Meng 和 Rubin(1993)提出, 是 EM 算法的拓展。该算法将 EM 算法的最大化步骤 (**M-step**) 替换成条件最大化步骤 (**CM-step**)。

将参数 $\boldsymbol{\theta}$ 划分成 $\boldsymbol{\theta}_1$ 和 $\boldsymbol{\theta}_2$, $Q(\boldsymbol{\theta})$ 为完全对数似然函数的期望, 则 **CM-step** 分为两小步:

CM-step1: 给定 $\boldsymbol{\theta}_2$ 的初始值, 关于 $\boldsymbol{\theta}_1$ 极大化 $Q(\boldsymbol{\theta})$, 得到 $\boldsymbol{\theta}_1$ 的估计值

$$\boldsymbol{\theta}_1^{(t+1)} = \underset{\boldsymbol{\theta}_1}{\text{Argmax}} Q(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2^{(t)} | \boldsymbol{\theta}^{(t)}) \quad (2.3)$$

CM-step2: 关于 θ_2 极大化 $Q(\theta)$, 得到 θ_2 的估计值

$$\theta_2^{(t+1)} = \underset{\theta_2}{\text{Argmax}} Q(\theta_1^{(t+1)}, \theta_2 | \theta^{(t)}) \quad (2.4)$$

• ECME 算法由 Liu 和 Rubin (1994) 提出, 是 ECM 算法的拓展。与 ECM 算法只有 CMQ 步骤不同, ECME 算法还有 CML 步骤, 即存在极大化 $\mathcal{L}(\theta)$ 的步骤。

若参数 θ 划分成 θ_1 和 θ_2 , 则 ECM 算法的 **CM-step2** 应替换为 CML 步骤, 即

$$\theta_2^{(t+1)} = \underset{\theta_2}{\text{Argmax}} \mathcal{L}(\theta_1^{(t+1)}, \theta_2) \quad (2.5)$$

第二节 矩阵正态分布和因子化主成分分析

一、矩阵正态分布

定义 2.1 若矩阵 $\mathbf{X} \in \mathbb{R}^{d_c \times d_r}$ 服从矩阵正态分布 $\mathbf{X} \sim \mathcal{N}_{d_c, d_r}(\mathbf{M}, \Sigma_c, \Sigma_r)$, 其中, $\mathbf{M} \in \mathbb{R}^{d_c \times d_r}$ 为均值矩阵, $\Sigma_c \in \mathbb{R}^{d_c \times d_c}$ 为行协方差矩阵, $\Sigma_r \in \mathbb{R}^{d_r \times d_r}$ 为列协方差矩阵, 向量化后 $\text{vec}(\mathbf{X}) \sim \mathcal{N}_{d_c d_r}(\text{vec}(\mathbf{M}), \Sigma_r \otimes \Sigma_c)$ 。 \mathbf{X} 的概率密度函数为:

$$p(\mathbf{X}) = (2\pi)^{-\frac{d_c d_r}{2}} |\Sigma_c|^{-\frac{d_r}{2}} |\Sigma_r|^{-\frac{d_c}{2}} \exp\{-\frac{1}{2} \delta_{\mathbf{X}}(\theta)\} \quad (2.6)$$

其中

$$\delta_{\mathbf{X}}(\theta) = \text{tr}[\Sigma_c^{-1}(\mathbf{X} - \mathbf{M})\Sigma_r^{-1}(\mathbf{X} - \mathbf{M})'] \quad (2.7)$$

由定义 2.1 可知, 所谓矩阵正态分布, 就是在多元正态分布的基础上具有可分离的协方差结构 $\Sigma = \Sigma_r \otimes \Sigma_c$ 。

二、因子化主成分分析

在主成分分析 (PCA) 中, 假定变量 \mathbf{x} 服从多元 t 分布, 其协差阵为 Σ , 对 \mathbf{x} 做正交线性变换 $\mathbf{y} = \mathbf{T}'\mathbf{x}$, 其中 $\mathbf{T} \in \mathbb{R}^{d \times q}$ 且 $q < d$, 那么 \mathbf{y} 的协差阵为 $\mathbf{T}'\Sigma\mathbf{T}$ 。 PCA 的目的是在目标函数中寻找最优的矩阵 \mathbf{T} (Jolliffe, 2002), 即

$$\max_{\mathbf{T}} \text{tr}\{\mathbf{T}'\Sigma\mathbf{T}\}, \text{ s.t. } \mathbf{T}'\mathbf{T} = \mathbf{I}_q \quad (2.8)$$

若变量服从矩阵正态分布，协方差阵被分解为 $\Sigma = \Sigma_r \otimes \Sigma_c$ ，相应地，矩阵 \mathbf{T} 被分解为 $\mathbf{T} = \mathbf{T}_r \otimes \mathbf{T}_c$ ，PCA 的目标函数则拆解成两个相互独立的子目标函数，即

$$\max_{\mathbf{T}_c} \text{tr}\{\mathbf{T}'_c \Sigma_c \mathbf{T}_c\}, s.t. \mathbf{T}'_c \mathbf{T}_c = \mathbf{I}_{q_c} \quad \text{和} \quad \max_{\mathbf{T}_r} \text{tr}\{\mathbf{T}'_r \Sigma_r \mathbf{T}_r\}, s.t. \mathbf{T}'_r \mathbf{T}_r = \mathbf{I}_{q_r} \quad (2.9)$$

Σ_c 和 Σ_r 的特征值与特征向量序列分别为 $\{(\mathbf{u}_i, \lambda_i)\}_{i=1}^c$ 和 $\{(\mathbf{v}_i, \eta_i)\}_{i=1}^r$ ，那么式 (2.9) 中优化问题的解分别为

$$\mathbf{T}_c = [\mathbf{u}_1, \dots, \mathbf{u}_{q_c}], \mathbf{T}_r = [\mathbf{v}_1, \dots, \mathbf{v}_{q_r}], \Sigma_c \text{ 和 } \Sigma_r \text{ 的前 } q_c, q_r \text{ 个特征向量} \quad (2.10)$$

由特征值所构成的对角矩阵为 $\Lambda_c = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_{q_c}\}$ 和 $\Lambda_r = \text{diag}\{\eta_1, \eta_2, \dots, \eta_{q_r}\}$ 。在矩阵正态分布的假定条件下，分别由式 (2.12) 中的 $\tilde{\Sigma}_c$ 和式 (2.13) 中的 $\tilde{\Sigma}_r$ 得到 Σ_c 和 Σ_r 的估计。

三、矩阵正态分布的极大似然估计

$\mathcal{X} = \{\mathbf{X}_n\}_{n=1}^N$ 是一组事先给定的观测，参数为 $\boldsymbol{\theta} = (\mathbf{M}, \Sigma_c, \Sigma_r)$ ，观测数据的对数似然函数 \mathcal{L} (省略常数项) 为

$$\mathcal{L}(\boldsymbol{\theta}|\mathcal{X}) = -\frac{1}{2} \sum_{n=1}^N \{d_r \ln |\Sigma_c| + d_c \ln |\Sigma_r| + \delta_{\mathbf{X}_n}(\boldsymbol{\theta})\} \quad (2.11)$$

其中 $\delta_{\mathbf{X}_n}(\boldsymbol{\theta})$ 由式 (2.7) 得到。

参数 \mathbf{M} 的极大似然估计为 $\bar{\mathbf{X}} = -\frac{1}{N} \sum_{n=1}^N \mathbf{X}_n$ ，令 $\mathbf{M} = \bar{\mathbf{X}}$ 。利用 CM 算法(Liu, Rubin, 1994) 迭代极大化似然函数 \mathcal{L} 可得到 Σ_c 和 Σ_r 的极大似然估计，分为两步：

CM-step1 : 给定 Σ_r ，关于 Σ_c 极大化似然函数 \mathcal{L} 得

$$\tilde{\Sigma}_c = \frac{1}{Nd_r} \sum_{n=1}^N (\mathbf{X}_n - \bar{\mathbf{X}}) \Sigma_r^{-1} (\mathbf{X}_n - \bar{\mathbf{X}})' \quad (2.12)$$

CM-step2 : 给定由 **CM-step1** 得到的 $\tilde{\Sigma}_c$, 关于 Σ_r 极大化似然函数 \mathcal{L} 得

$$\tilde{\Sigma}_r = \frac{1}{Nd_c} \sum_{n=1}^N (\mathbf{X}_n - \bar{\mathbf{X}})' \tilde{\Sigma}_c^{-1} (\mathbf{X}_n - \bar{\mathbf{X}}) \quad (2.13)$$

循环 **CM-step1** 和 **CM-step2** 两个步骤, 当对数似然 \mathcal{L} 的值小于某个给定的取值时, 退出迭代过程。

第三节 矩阵变元 t 分布和基于矩阵变元 t 分布的稳健因子主成分分析

为方便后续推导使用, 先对伽玛分布的相关知识进行简要介绍(Bishop, Nasrabadi, 2006)。

若变量 τ 服从伽玛分布 $\tau \sim \text{Ga}(\alpha, \beta)$, τ 和 $\ln \tau$ 的期望分别为

$$\mathbb{E}[\tau] = \frac{\alpha}{\beta} \quad (2.14)$$

$$\mathbb{E}[\ln \tau] = \psi(\alpha) - \ln \beta \quad (2.15)$$

其中 $\psi(x) = d \ln(\Gamma(x))/dx$ 为 digamma 函数。

一、矩阵变元 t 分布

定义 2.2 称矩阵 $\mathbf{X} \in \mathbb{R}^{d_c \times d_r}$ 服从矩阵变元 t 分布 $\mathbf{X} \sim Mt_{d_c, d_r}(\mathbf{M}, \Sigma_c, \Sigma_r, \nu)$, 其中 $\mathbf{M} \in \mathbb{R}^{d_c \times d_r}$ 为均值矩阵, $\Sigma_c \in \mathbb{R}^{d_c \times d_c}$ 为行协方差矩阵, $\Sigma_r \in \mathbb{R}^{d_r \times d_r}$ 为列协方差矩阵且 ν 为自由度, 向量化后 $\text{vec}(\mathbf{X}) \sim t_{d_c d_r}(\text{vec}(\mathbf{M}), \Sigma_r \otimes \Sigma_c, \nu)$ 。 \mathbf{X} 的概率密度函数为:

$$p(\mathbf{X}) = \frac{|\Sigma_c|^{-\frac{d_r}{2}} |\Sigma_r|^{-\frac{d_c}{2}} \Gamma(\frac{\nu + d_c d_r}{2})}{(\pi \nu)^{\frac{d_c d_r}{2}} \Gamma(\frac{\nu}{2})} \left(1 + \frac{\delta_{\mathbf{X}}(\boldsymbol{\theta})}{\nu} \right)^{-\frac{\nu + d_c d_r}{2}} \quad (2.16)$$

其中 $\delta_{\mathbf{X}}(\boldsymbol{\theta})$ 见于式 (2.7)。

矩阵 \mathbf{X} 可以在引入一个权重变量 τ 的条件下表示为一个潜变量模型。在 τ 服从伽玛分布 $\text{Ga}(\nu/2, \nu/2)$ 的条件下, 矩阵 $\mathbf{X} \in \mathbb{R}^{d_c \times d_r}$ 服从矩阵变元正态分布

$\mathcal{N}_{d_c, d_r}(\mathbf{W}, \Sigma_c/\tau, \Sigma_r)$, 即

$$\begin{cases} \mathbf{X}|\tau \sim \mathcal{N}_{d_c, d_r}(\mathbf{W}, \Sigma_c/\tau, \Sigma_r) \\ \tau \sim \text{Ga}(\nu/2, \nu/2) \end{cases} \quad (2.17)$$

根据式 (2.17), 可得边际分布 $\mathbf{X} \sim Mt_{d_c, d_r}(\mathbf{M}, \Sigma_c, \Sigma_r, \nu)$ 或 $\text{vec}(\mathbf{X}) \sim t_{d_c d_r}(\text{vec}(\mathbf{M}), \Sigma_r \otimes \Sigma_c, \nu)$ 。 \mathbf{X} , 其协方差矩阵为

$$\text{cov}(\text{vec}(\mathbf{X})) = \frac{\nu}{\nu - 2} \Sigma_r \otimes \Sigma_c \quad (2.18)$$

其后验分布为

$$\tau|\mathbf{X} \sim \text{Ga}\left(\frac{\nu + d_c d_r}{2}, \frac{\nu + \delta_{\mathbf{X}}(\boldsymbol{\theta})}{2}\right) \quad (2.19)$$

二、稳健因子主成分分析

在矩阵变元 t 分布的假定条件下, 存在式 (2.18) 中给出的协差阵的分解。在省略常数的情形下, 将分解 $\Sigma = \Sigma_r \otimes \Sigma_c$ 代入式 (2.9) 和式 (2.10), 得到 RFPCA 中优化问题的解 \mathbf{T}_c 和 \mathbf{T}_r , Σ_c 和 Σ_r 的估计分别由式 (2.25) 中的 $\tilde{\Sigma}_c$ 和式 (2.26) 中的 $\tilde{\Sigma}_r$ 得到。

三、矩阵变元 t 分布的极大似然估计

$\mathcal{X} = \{\mathbf{X}_n\}_{n=1}^N$ 是一组事先给定的观测, 参数 $\boldsymbol{\theta} = (\mathbf{M}, \Sigma_c, \Sigma_r, \nu)$, 根据式 (2.16), 观测数据的对数似然函数 \mathcal{L} 为

$$\begin{aligned} \mathcal{L}(\boldsymbol{\theta}|\mathcal{X}) = & -\frac{N}{2} [d_c d_r \ln \pi + d_r \ln |\Sigma_c| + d_c \ln |\Sigma_r| + 2 \ln \Gamma\left(\frac{\nu}{2}\right) - 2 \ln \Gamma\left(\frac{\nu + d_c d_r}{2}\right) \\ & - \nu \ln \nu] - \frac{\nu + d_c d_r}{2} \sum_{n=1}^N \ln(\nu + \delta_{\mathbf{X}_n}(\boldsymbol{\theta})) \end{aligned} \quad (2.20)$$

其中 $\delta_{\mathbf{X}_n}(\boldsymbol{\theta})$ 由式 (2.7) 得到。直接极大化式 (2.20) 中的 \mathcal{L} 来估计参数是很困难的, 所以利用 EM 型算法来进行参数估计。

• ECM 算法含有一个求条件期望的步骤 (E-step) 以及四个在给定参数下极大化条件期望的步骤 (CM-steps):

E-step: 给定一组缺失数据 $\boldsymbol{\tau} = \{\tau_n\}_{n=1}^N$, 此时完全数据的对数似然函数可表示为 $\sum_{n=1}^N \ln\{p(\mathbf{X}_n|\tau_n)p(\tau_n)\}$, 将其关于条件分布 $p(\boldsymbol{\tau}|\mathcal{X}, \boldsymbol{\theta})$ 求期望, 可得

$$\begin{aligned}
 \mathcal{Q}(\boldsymbol{\theta}|\mathcal{X}) &= -\frac{N}{2}[d_c d_r \ln(2\pi) + d_r \ln |\boldsymbol{\Sigma}_c| + d_c \ln |\boldsymbol{\Sigma}_r|] + \frac{d_c d_r}{2} \sum_{n=1}^N \mathbb{E}(\ln \tau_n | \mathbf{X}_n) \\
 &\quad - \frac{1}{2} \sum_{n=1}^N \mathbb{E}(\tau_n | \mathbf{X}_n) \delta_{\mathbf{X}_n}(\boldsymbol{\theta}) + N \left[\frac{\nu}{2} \ln \left(\frac{\nu}{2} \right) - \ln \Gamma \left(\frac{\nu}{2} \right) \right] \\
 &\quad + \left(\frac{\nu}{2} - 1 \right) \sum_{n=1}^N \mathbb{E}(\ln \tau_n | \mathbf{X}_n) - \frac{\nu}{2} \sum_{n=1}^N \mathbb{E}(\tau_n | \mathbf{X}_n)
 \end{aligned} \tag{2.21}$$

由式 (2.14)、(2.15) 和 (2.19) 可得上式 (2.21) 中的期望为

$$\mathbb{E}[\tau_n | \mathbf{X}_n] = \frac{\nu + d_c d_r}{\nu + \delta_{\mathbf{X}_n}(\boldsymbol{\theta})} \tag{2.22}$$

$$\mathbb{E}[\ln \tau_n | \mathbf{X}_n] = \psi \left(\frac{\nu + d_c d_r}{2} \right) - \ln \left(\frac{\nu + \delta_{\mathbf{X}_n}(\boldsymbol{\theta})}{2} \right) \tag{2.23}$$

其中 $\delta_{\mathbf{X}_n}(\boldsymbol{\theta})$ 由式 (2.7) 得到, $\mathbb{E}[\tau_n | \mathbf{X}_n]$ 是权重的期望。

CM-step1: 在给定 $(\boldsymbol{\Sigma}_c, \boldsymbol{\Sigma}_r, \nu)$ 的条件下, 关于 \mathbf{M} 极大化 **E-step** 中的 \mathcal{Q} , 得

$$\tilde{\mathbf{M}} = \frac{\sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] \mathbf{X}_n}{\sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n]} \tag{2.24}$$

CM-step2: 得到 **CM-step1** 中的 $\tilde{\mathbf{M}}$ 后, 给定 $(\tilde{\mathbf{M}}, \boldsymbol{\Sigma}_r, \nu)$, 关于 $\boldsymbol{\Sigma}_c$ 极大化 \mathcal{Q} , 得

$$\tilde{\boldsymbol{\Sigma}}_c = \frac{1}{N d_r} \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] (\mathbf{X}_n - \tilde{\mathbf{M}}) \boldsymbol{\Sigma}_r^{-1} (\mathbf{X}_n - \tilde{\mathbf{M}})' \tag{2.25}$$

CM-step3: 得到 **CM-step2** 中的 $\tilde{\boldsymbol{\Sigma}}_c$ 后, 给定 $(\tilde{\mathbf{M}}, \tilde{\boldsymbol{\Sigma}}_c, \nu)$, 关于 $\boldsymbol{\Sigma}_r$ 极大化 \mathcal{Q} , 得

$$\tilde{\boldsymbol{\Sigma}}_r = \frac{1}{N d_c} \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] (\mathbf{X}_n - \tilde{\mathbf{M}})' \tilde{\boldsymbol{\Sigma}}_c^{-1} (\mathbf{X}_n - \tilde{\mathbf{M}}) \tag{2.26}$$

CM-step4: 得到 **CM-step3** 中的 $\tilde{\boldsymbol{\Sigma}}_r$ 后, 给定 $(\tilde{\mathbf{M}}, \tilde{\boldsymbol{\Sigma}}_c, \tilde{\boldsymbol{\Sigma}}_r)$, 关于 ν 极大化 \mathcal{Q} , 得

$$\tilde{\nu} = \frac{2}{y + \ln y - 1} + 0.0416 \times [1 + \text{erf}(0.6594 \times \ln \frac{2.1971}{y + \ln y - 1})] \tag{2.27}$$

其中 $y = -\frac{1}{N} \sum_{n=1}^N \{\mathbb{E}[\ln \tau_n | \mathbf{X}_n] - \mathbb{E}[\tau_n | \mathbf{X}_n]\}$, $erf(x) = \frac{2}{\sqrt{\pi}} \int_0^x \exp(-t^2) dt$

• ECME 算法与 ECM 算法一样, 也分为 E-step 和 CM-steps, 但 ECME 对于参数 ν 的更新是通过极大化对数似然函数 \mathcal{L} 实现的, 即

CM-step4: 给定 $(\tilde{\mathbf{M}}, \tilde{\Sigma}_c, \tilde{\Sigma}_r)$, 关于 ν 极大化式 (2.20) 中的对数似然 \mathcal{L} , 让 \mathcal{L} 对于 ν 的导数为 0, 可得

$$1 + \psi\left(\frac{\nu + d_c d_r}{2}\right) - \ln\left(\frac{\nu + d_c d_r}{2}\right) - \psi\left(\frac{\nu}{2}\right) + \ln\frac{\nu}{2} + \frac{1}{N} \sum_{n=1}^N \left[\ln \frac{\nu + d_c d_r}{\nu + \delta_{\mathbf{X}_n}(\theta)} - \frac{\nu + d_c d_r}{\nu + \delta_{\mathbf{X}_n}(\theta)} \right] = 0 \quad (2.28)$$

ν 的更新 $\tilde{\nu}$ 通过求解上述式子得到。

算法 1 展示了 RFPCA 的完整的 ECM 算法和 ECME 算法。

算法 1: RFPCA 的 ECM 算法 (ECME 算法)

输入: 观测数据 \mathcal{X} 和参数 $\theta = (\mathbf{M}, \Sigma_c, \Sigma_r, \nu)$ 的初始值

1 循环下述五个步骤:

2 E-step: 计算条件期望 $\mathbb{E}[\tau_n | \mathbf{X}_n] = (\nu + d_c d_r) / (\nu + \delta_{\mathbf{X}_n}(\theta))$

3 CM-step1: $\tilde{\mathbf{M}} = \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] \mathbf{X}_n / \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n]$

4 CM-step2: $\tilde{\Sigma}_c = \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] (\mathbf{X}_n - \tilde{\mathbf{M}}) \Sigma_r^{-1} (\mathbf{X}_n - \tilde{\mathbf{M}})' / N d_r$

5 CM-step3: $\tilde{\Sigma}_r = \sum_{n=1}^N \mathbb{E}[\tau_n | \mathbf{X}_n] (\mathbf{X}_n - \tilde{\mathbf{M}})' \tilde{\Sigma}_c^{-1} (\mathbf{X}_n - \tilde{\mathbf{M}}) / N d_c$

6 CM-step4:

$$\tilde{\nu} = 2 / (y + \ln y - 1) + 0.0416 \times [1 + erf(0.6594 \times \ln(2.1971 / (y + \ln y - 1)))]$$

(通过式 (2.28) 得到 $\tilde{\nu}$ 的解)

7 直到对数似然 \mathcal{L} 的值小于某个给定的取值

输出: $\tilde{\theta} = (\tilde{\mathbf{M}}, \tilde{\Sigma}_c, \tilde{\Sigma}_r, \tilde{\nu})$

四、极大似然估计不存在的情形

在高维矩阵型数据上, RFPCA 利用极大似然估计 (ML Estimation, MLE) 来对参数列协方差矩阵 Σ_c 和行协方差矩阵 Σ_r 进行估计时, 容易存在矩阵奇异或退化问题, 此时, 无法得到 Σ_c 和 Σ_r 的 ML 估计。

MLE 的存在性与矩阵维数和样本量 $(m1, m2, n)$ 相关, Drton et al. (2021) 提出了三种 ML 阈值, 即存在性阈值 $N_e(m1, m2)$ 、唯一性阈值 $N_u(m1, m2)$ 和有界阈值 $N_b(m1, m2)$, 分别表示: 若 $n \geq N_e(m1, m2)$, MLE 存在, 若 $n \geq N_u(m1, m2)$, 有唯一的 MLE 值, 若 $n \geq N_b(m1, m2)$, ML 有界。三种 ML 阈值满足

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/998012025025007010>