

SVD 展开方法详解 (Höcker-Kartvelishvili Unfolding)

1. 基本设定

待测物理量为真实的刚度谱 $f(R_{\text{true}})$, 探测器实测谱为 $g(R_{\text{meas}})$ 。将连续谱离散化到 n 个测量 bin 和 m 个真实 bin, 记 f_j 为真实第 j 个 bin 的事例数, g_i 为测量第 i 个 bin 的事例数。探测器响应用迁移矩阵 A_{ij} 表示: A_{ij} 是真实处于 bin j 的事例被测量到 bin i 的概率, 满足 $\sum_i A_{ij} = 1$ 。

于是有线性模型

$$g_i = \sum_{j=1}^m A_{ij} f_j + \varepsilon_i$$

或写为矩阵形式

$$\mathbf{g} = \mathbf{A} \mathbf{f} + \boldsymbol{\varepsilon}$$

其中 $\boldsymbol{\varepsilon}$ 为测量统计噪声 (通常假定服从高斯分布, 协方差矩阵 \mathbf{V} 可估)。

目标: 已知测量值 \mathbf{g} 、迁移矩阵 \mathbf{A} (由蒙特卡罗模拟确定), 估计真实谱 \mathbf{f} 。

2. 直接反演的病态性

如果用最小二乘法直接最小化 $\chi^2 = (\mathbf{g} - \mathbf{A} \mathbf{f})^\top \mathbf{V}^{-1} (\mathbf{g} - \mathbf{A} \mathbf{f})$, 正规方程为

$$\mathbf{A}^\top \mathbf{V}^{-1} \mathbf{A} \mathbf{f} = \mathbf{A}^\top \mathbf{V}^{-1} \mathbf{g}$$

解得

$$\mathbf{f} = (\mathbf{A}^\top \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^\top \mathbf{V}^{-1} \mathbf{g}$$

但迁移矩阵 \mathbf{A} 是病态的: 相邻 bin 的迁移概率高度相关, 小奇异值对应的模式对噪声极其敏感。直接求逆会产生剧烈振荡的解, 甚至出现负值事例数。

SVD 方法正是通过截断小奇异值来正则化, 牺牲部分分辨率以换取解的稳定性。

3. SVD 分解与正则化

3.1 规范化矩阵

为简化, 引入规范化协方差矩阵, 通常使用对数似然拟合或平方根矩阵。经典做法是定义

$$\mathbf{C} = \mathbf{V}^{-1/2} \mathbf{A} \quad \text{和} \quad \mathbf{y} = \mathbf{V}^{-1/2} \mathbf{g}$$

其中 $\mathbf{V}^{-1/2}$ 是 \mathbf{V}^{-1} 的对称平方根。则将问题转化为普通最小二乘：

$$\chi^2 = \|\mathbf{y} - \mathbf{C}\mathbf{f}\|^2$$

正规方程变成 $\mathbf{C}^\top \mathbf{C} \mathbf{f} = \mathbf{C}^\top \mathbf{y}$ 。

3.2 奇异值分解

对矩阵 \mathbf{C} (尺寸 $n \times m$, 通常 $n \geq m$) 进行 SVD:

$$\mathbf{C} = \mathbf{U} \mathbf{\Sigma} \mathbf{W}^\top$$

其中:

- \mathbf{U} 是 $n \times n$ 正交矩阵, 列向量 $\{\mathbf{u}_k\}$ 是左奇异向量;
- \mathbf{W} 是 $m \times m$ 正交矩阵, 列向量 $\{\mathbf{w}_k\}$ 是右奇异向量;
- $\mathbf{\Sigma}$ 是 $n \times m$ 对角矩阵, 对角元 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_m \geq 0$ 为奇异值。

3.3 正则化的形式

利用 SVD, 正规方程 $\mathbf{C}^\top \mathbf{C} \mathbf{f} = \mathbf{C}^\top \mathbf{y}$ 的解可表为

$$\mathbf{f}_{\text{reg}} = \sum_{k=1}^m d_k \mathbf{w}_k$$

其中系数

$$d_k = \frac{\mathbf{u}_k^\top \mathbf{y}}{\sigma_k}$$

如果保留所有奇异值, 这就是未经正则化的普通最小二乘解。由于小 σ_k 对应的项对噪声极其敏感 (分母很小, 放大了 \mathbf{y} 中的统计涨落), SVD 正则化通过引入**衰减因子** ϕ_k 来抑制这些项:

$$\mathbf{f}_{\text{reg}} = \sum_{k=1}^m \phi_k \frac{\mathbf{u}_k^\top \mathbf{y}}{\sigma_k} \mathbf{w}_k$$

最简单的选择是硬截断: 取某个正整数 $k_{\text{max}} < m$, 令

$$\phi_k = \begin{cases} 1, & k \leq k_{\text{max}} \\ 0, & k > k_{\text{max}} \end{cases}$$

更平滑的衰减函数 (如 Tikhonov 型 $\phi_k = \frac{\sigma_k^2}{\sigma_k^2 + \tau^2}$) 也可引入。

4. 正则化参数的选择

硬截断时, 截断阶数 k_{max} (或 Tikhonov 参数 τ) 决定了平滑程度:

- k_{max} 过大: 保留太多噪声, 解出现剧烈振荡;

- k_{\max} 过小：解过于平滑，丢失真实谱的细节（偏差增大）。

选择方法：

- **与蒙特卡罗真值对比**：用已知真实谱的模拟数据测试不同 k_{\max} ，选择使偏差和方差综合最优者；
- **L-曲线法**：绘制解的范数 $\|\mathbf{f}_{\text{reg}}\|^2$ 与残差范数 $\|\mathbf{y} - \mathbf{C}\mathbf{f}_{\text{reg}}\|^2$ 的双对数曲线，拐点对应最佳平衡点；
- **交叉验证**：在真实数据中谨慎使用，容易因 bin 间相关性产生误导。

5. 误差传播与协方差

SVD 展开的解是 \mathbf{g} 的线性函数，因此解的后验协方差矩阵可直接计算：

$$\text{Cov}(\mathbf{f}_{\text{reg}}) = \sum_{k=1}^m \phi_k^2 \frac{\mathbf{w}_k \mathbf{w}_k^\top}{\sigma_k^2}$$

这反映了由于数据统计误差引起的解的统计不确定性。注意截断会同时引入偏差，完整的误差评估需同时考虑统计误差和正则化偏差。

6. 优缺点与使用注意

优点：

- 数学框架清晰，基于线性代数，实现简单；
- 正则化强度通过截断阶数直观控制；
- 适用于测量 bin 数不小于真实 bin 数的一般情况。

缺点：

- 假设测量误差为高斯分布且协方差矩阵已知，对低统计量或非高斯情形不稳健；
- 需要充分的蒙特卡罗模拟以构建准确的迁移矩阵和协方差矩阵；
- 硬截断会在 bin 之间产生与正则化阶数相关的相关性结构，需要谨慎诠释；
- 对小信号分量（在某些 bin 统计不足）可能仍有偏。

在径迹探测器刚度谱 unfolding 中，SVD 方法常与贝叶斯迭代方法对比。当探测分辨率造成的 bin 迁移主要限制在相邻几个 bin 时，SVD 正则化能有效消除统计振荡，并保持边缘的形状。实际使用时，一般会与多种方法交叉验证，确保结果不依赖于特定正则化策略。

7. 总结

SVD 展开通过在奇异值空间中截断小奇异值，滤除噪声主导的模式，使得线性反演问题从病态变为适定。其核心是**用偏差换取方差减小**，在提高谱分辨率与保证统计稳定性之间取得平衡。正确应用的关键在于选择合理的正则化参数，并对解的不确定性（包括统计误差和系统性偏差）进行全面估计。