

金属物探资料数据处理参考资料

赠阅

国家计委地质局150工程方法组
武汉地质学院物探、数学教研室

1974年12月

地球物理学报
编辑部

221

W

目 录

1.	一种最小平方估计非线性参数的算法	1
2.	三度棱柱磁力异常的自动解释	17
3.	磁测解释的自动最小二乘复合模型法	49
4.	电子数字计算机上激发体轮廓的自动选择	65
5.	解重力反问题时多元函数极小值的一种算法	70
6.	位场反问题的一种解法	75
7.	重磁异常解释中区域背景的划分问题	84
8.	应用原核模型进行自动磁法解释的经验	89
9.	应用数字计算机获得重力异常数据的迭代三维解	111
10.	用整数线性规划解稀疏的 反问题	120

11.	重力解释的最小二乘法	-----	131
12.	组合激发体重力反问题的解法	-----	138
13.	重力异常剖面迭代分析中改进收敛性	-----	146
14.	应用垂直棱柱模型的磁异常的自动解释	-----	155
15.	重力异常剖面迭代分析中改进收敛性	-----	173

一种最小平方估计非线性参数的算法

D. W. MARQUARDT

引言 最小平方估计非线性参数的许多算法都是围绕两条途径之一。一方面，模型可展成台劳级数，并且在局部线性的假设下，每次迭代中，参数的校正值都可以算出。另一方面，则是应用各种改进后的最速下降法。这两种方法常常行到搁浅。台劳级数方法是由于逐步迭代发散所致，最速下降法（或斜量法）则是由于开头几次迭代后就发生烦恼的缓慢收敛。

本文开展一种最大邻域的方法，它实际上就是在台劳级数法与斜量法之间进行内插。这种内插是基于最大邻域，在此领域中，截断台劳级数给出非线性模型的一个合适的表示。

所有的结果都可以推广到非线性代数方程组的求解问题上去。

问题的陈述 设拟合数据的模型为

$$(1) \quad E(y) = f(x_1, x_2, \dots, x_m; \beta_1, \beta_2, \dots, \beta_k) = f(x, \beta)$$

其中 x_1, x_2, \dots, x_m 是自变量； $\beta_1, \beta_2, \dots, \beta_k$ 是 k 个参数的母体值， $E(y)$ 是因变量的期望值。

数据点记为

$$(2) \quad (Y_i, Z_{1i}, Z_{2i}, \dots, Z_{mi}), \quad i = 1, 2, \dots, n.$$

于是问题就是要计算这些参数的估计值使得

$$(3) \quad \Phi = \sum_{i=1}^n [Y_i - \hat{Y}_i]^2 = \|Y - \hat{Y}\|^2$$

为最小，其中 \hat{Y}_i 表示在第 i 数据点，由 (1) 预测的 y 值。

人所熟知，当 f 是 β 的线性函数时， \underline{y} 的等值面是椭球面，当 f 是 β 的非线性函数时，等值面随着非线性的严重程度发生畸变。不过，就是非线性模型的情况，等值面在 \underline{y} 的极小点附近仍然近似于椭球面。典型的情况是： \underline{y} 的等值面在某一方向缩得很短，在另一方向又拉得很长以致极小点就位于一个长曲槽的底部。

本文只专注于得出最小平方估计的算法。至于非线性估计的更广泛的统计性态及其在特定问题中的应用，读者可阅参考文献中 [1], [2], [4], [5], [6] 各项。其它参考资料也都在所引用的文章中。

通用的方法 下面是基于把函数 f 展成台劳级数的方法（通常指为高斯方法 [1], [7] 或高斯—牛顿方法 [4]）把台劳级数只写到一次项

$$(4) \langle Y(\underline{z}_i, \underline{b} + \underline{d}_t) \rangle = f(\underline{z}_i, \underline{b}) + \sum_{j=1}^k \left(\frac{\partial f_i}{\partial b_j} \right) (d_t)_j$$

或

$$(4a) \langle \underline{Y} \rangle = \underline{f}_0 + P \underline{d}_t$$

在 (4) 中，记号 \underline{b} 代替 β ， \underline{b} 的收敛值就是 β 的最小平方估计值。向量 \underline{d}_t 表示 \underline{b} 的校正值，下标 t 用以表示它是由台劳级数方法计算出来的，括号 $\langle \rangle$ 用以区别它是基于线性化后模型的预测，而不是基于实际非线性模型的预测。于是由 (4) 预测到 \underline{y} 的值为

$$(5) \langle \underline{y} \rangle = \sum_{i=1}^n [Y_i - \langle Y_i \rangle]^2$$

在 (4) 中， \underline{d}_t 只线性地出现，所以可按标准的最小二乘法求

出, 即对于一切 j , 令 $\frac{\partial \langle \Phi \rangle}{\partial b_j} = 0$, 于是 \underline{d}_t 可从下面方程组解出,

$$(6) \quad \underline{A} \underline{d}_t = \underline{g},$$

其中

$$(7) \quad \underline{A}^{[k \times k]} = \underline{P}^T \underline{P},$$

$$(8) \quad \underline{P}^{[n \times k]} = \left(\frac{\partial f_i}{\partial b_j} \right), \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, k$$

$$(9) \quad \underline{g}^{[k \times 1]} = \left(\sum_{i=1}^n (Y_i - f_i) \frac{\partial f_i}{\partial b_j} \right), \quad j = 1, 2, \dots, k$$

$$= \underline{P}^T (\underline{Y} - \underline{f}_0)$$

在实践中发现只用 \underline{d}_t 的一小部分来校正 \underline{b} 倒是很有帮助的, 否则可能会外推到不能由 (4) 合适地表示的范围之外, 以致迭代发散。因此一旦方向由 \underline{d}_t 确定后, 有各种方法 (1), (4), (6) 可以用来确定一个恰当的步长 $K \underline{d}_t$, $0 < K \leq 1$ 。但是, 就是这样做, 不收敛情形也是常有的。

与此对比, 计量法却是简单地从现有的试探值沿 \underline{b} 的负梯度方向迈出一步, 所以

$$(10) \quad \underline{d}_g = - \left(\frac{\partial \Phi}{\partial b_1}, \frac{\partial \Phi}{\partial b_2}, \dots, \frac{\partial \Phi}{\partial b_k} \right)^T$$

有各种改进的最速下降法 [5], 是用来部分地弥补 \underline{b} 的等值面特别坏, 它使斜量法收敛得极其缓慢的情况。用这些改进的斜量法, 也跟用台劳级数法一样, 当校正 \underline{b} 的方向确定后, 还

注 1 上标 T 表示矩阵的转置

必须谨慎地控制步长。虽然这样做，缓慢的收敛性仍是常见，并非例外。

在各种关于 f 的性质的假设下，已推得台劳级数方法收敛性的多种证明〔4〕，〔7〕，也推得斜量法收敛性的各种证明〔3〕。然而，在迭代过程中，假定 f 是很好的函数，并假定有无穷多恰当的算术运算过程，关于 \mathbf{z} 的单调性的数学证明最好的也不过是一种关于收敛性的必要条件。这些证明，它们本身并不给出收敛速度的合适指示。我们必须从理论上说是收敛的一类方法中，找出这样的方法，它对于大多数问题，确实是只用有限次算术运算就能迅速收敛的。

问题的定性分析 鉴于台劳级数法与斜量法都有不适用性，我们最好还是来检查一下有关的原理。首先，任何一个用的方法应该使校正向量的方向与 \mathbf{z} 的负梯度方向的夹角是在 90° 之内。否则 \mathbf{z} 沿着校正向量的各点处的值会变大而不是变小。其次，由于在许多问题中， \mathbf{z} 曲面的严重拉长， \underline{d}_t 常与 \underline{d}_g 成了几乎是 90° 的角（事实上，我们已对各种各样问题调整过这个 γ 角，发现 γ 经常是在 $0 < \gamma < 90^\circ$ 范围之内）。从这些来考虑，这样说似乎是合理的。即任何一种改进的方法从某种意义上说，就是在 \underline{d}_t 与 \underline{d}_g 之间进行内插。

上述这两种方法都暗含着这个意思，即在确定满意的步长之前，应选择好校正向量的方向。然而在将要描述的算法中，方向与步长却是同时确定的。

算法的理论基础 算法的理论基础包含在下面几个定理之中。定理 1 与定理 2 是 Morrison 的〔7〕。这里，对定理 1 的证明与 Morrison 的证明不同。这里的证明也许对所包含的

几何关系会提供较深的看法。

定理1 设 $\lambda \geq 0$ 是任意的, 设 \underline{d}_0 满足方程

$$(10) \quad (\underline{A} + \lambda \underline{I}) \underline{d}_0 = \underline{g}.$$

则 \underline{d}_0 在半径 $\|\underline{d}\|$ 满足 $\|\underline{d}\|^2 = \|\underline{d}_0\|^2$ 的球面上使 $\langle \underline{v}, \underline{d} \rangle$ 为最小。

证: 为了求出 \underline{d} 使

$$(11) \quad \langle \underline{v}, \underline{d} \rangle = \|\underline{Y} - \underline{f}_0 - \underline{P}\underline{d}\|^2$$

在约束条件

$$(12) \quad \|\underline{d}\|^2 = \|\underline{d}_0\|^2$$

下为最小, 根据拉格朗日方法, 产生驻点的必要条件为

$$(13) \quad \frac{\partial u}{\partial \underline{d}_1} = \frac{\partial u}{\partial \underline{d}_2} = \dots = \frac{\partial u}{\partial \underline{d}_k} = 0, \quad \frac{\partial u}{\partial \lambda} = 0.$$

其中

$$(14) \quad u(\underline{d}, \lambda) = \|\underline{Y} - \underline{f}_0 - \underline{P}\underline{d}\|^2 + \lambda(\|\underline{d}\|^2 - \|\underline{d}_0\|^2)$$

λ 是拉格朗日乘数, 求上列各导数, 得

$$(15) \quad 0 = -[\underline{P}^T(\underline{Y} - \underline{f}_0) - \underline{P}^T \underline{P} \underline{d}] + \lambda \underline{d},$$

$$(16) \quad 0 = \|\underline{d}\|^2 - \|\underline{d}_0\|^2$$

对于给定的 λ , 方程

$$(17) \quad (\underline{P}^T \underline{P} + \lambda \underline{I}) \underline{d} = \underline{P}^T(\underline{Y} - \underline{f}_0)$$

的解 \underline{d} 满足 (15)。将 (17) 左乘以 $(\underline{P}^T \underline{P})^{-1}$, 并写成这样形式

$$(18) \quad \underline{d} = (\underline{P}^T \underline{P})^{-1} \underline{P}^T(\underline{Y} - \underline{f}_0) - (\underline{P}^T \underline{P})^{-1} \lambda \underline{d},$$

然后代入 (15) 就可验证这一点。^{译者注} (10) 与 (17) 是同一个方

^{译者注} 还可简单地验证: 从 (17) 式移项得 $\underline{P}^T \underline{P} + \lambda \underline{I} \underline{d} - \underline{P}^T(\underline{Y} - \underline{f}_0) = 0$,

$-(\underline{P}^T(\underline{Y} - \underline{f}_0) - \underline{P}^T \underline{P} \underline{d}) + \lambda \underline{d} = 0$, 可见方程 (17) 的解必满足 (15)。

程, 从 $(A + \lambda I)$ 是正定的这个事实, 显然这个驻点实际上就是极小点.

定理 2 设 $\underline{d}(\lambda)$ 是方程组 (10), 对应于给定 λ 的解, 则 $\|\underline{d}(\lambda)\|^2$ 是 λ 的这样连续递减函数, 当 $\lambda \rightarrow \infty$ 时, $\|\underline{d}(\lambda)\|^2 \rightarrow 0$.

证: 因为对称矩阵 A 是正定的, 可用一个正交规范转轴变换把 A 化成对角线矩阵 D , 并保持两点间距离不变. 记此变换为 $S^T A S = D$, 这里 $S^T S = I$, 又 D 的对角线上元素均为正. 这样, (10) 就取这样形状: $(D + \lambda I) S^{-1} \underline{d}_0 = S^T \underline{g}$, 从而得

$$(19) \quad \underline{d}_0 = S(D + \lambda I)^{-1} S^T \underline{g}$$

于是, 令 $\underline{V} = S^T \underline{g}$, 得

$$\begin{aligned} \|\underline{d}_0(\lambda)\|^2 &= \underline{g}^T S(D + \lambda I)^{-1} S^T S(D + \lambda I)^{-1} S^T \underline{g} \\ &= \underline{V}^T [(D + \lambda I)^2]^{-1} \underline{V} \\ (20) \quad &= \sum_{j=1}^k \frac{V_j^2}{(D_j + \lambda)^2} \end{aligned}$$

显然这是 λ 的递减函数 ($\lambda \geq 0$). 故当 $\lambda \rightarrow \infty$ 时, $\|\underline{d}_0(\lambda)\|^2 \rightarrow 0$.

这里已显明地揭示正交规范变换把矩阵变成对角线形状, 这是为了便于下面定理的证明.

定理 3. 设 γ 是 \underline{d}_0 与 \underline{d}_g 之间的夹角, 则 γ 是 λ 的这样单调递减函数, 当 $\lambda \rightarrow \infty$ 时, $\gamma \rightarrow 0$. 由于 \underline{d}_g 不依赖于 λ , 所以当 $\lambda \rightarrow \infty$ 时 \underline{d}_0 转向 \underline{d}_g .

证: 首先观察

$$(21) \quad \underline{d}_g = \left(\sum_{i=1}^n (Y_i - f_i) \frac{\partial f_i}{\partial b_j} \right)^T, \quad j = 1, 2, \dots, k.$$

因此(除差一个比例因子, 不过这是无关紧要的, 因为有关的仅是向量的方向)

$$(22) \quad \underline{\sigma}_g = \underline{g}.$$

根据 γ 角的定义

$$\begin{aligned} \cos \gamma &= \frac{\underline{f}^T \underline{g}}{(\|\underline{f}\|)(\|\underline{g}\|)} \\ &= \frac{\underline{V}^T (\underline{D} + \lambda \underline{I})^{-1} \underline{V}}{(\underline{V}^T [(\underline{D} + \lambda \underline{I})^2]^{-1} \underline{V})^{1/2} (\underline{g}^T \underline{g})^{1/2}} \\ &= \frac{\sum_{j=1}^K \frac{V_j^2}{D_j + \lambda}}{\left[\sum_{j=1}^K \frac{V_j^2}{(D_j + \lambda)^2} \right]^{1/2} (\underline{g}^T \underline{g})^{1/2}} \end{aligned}$$

求导并化简, 得

$$(24) \quad \frac{d}{d\lambda} \cos \gamma = \frac{\left[\sum_{j=1}^K \frac{V_j^2}{D_j + \lambda} \right] \left[\sum_{j=1}^K \frac{V_j^2}{(D_j + \lambda)^3} \right] - \left[\sum_{j=1}^K \frac{V_j^2}{(D_j + \lambda)^2} \right]^2}{\left[\sum_{j=1}^K \frac{V_j^2}{(D_j + \lambda)^2} \right]^{3/2} (\underline{g}^T \underline{g})^{1/2}}$$

$$(25) \quad = \frac{\left[\sum_{j=1}^K V_j^2 \Pi_{1j} \right] \left[\sum_{j=1}^K V_j^2 \Pi_{3j} \right] - \left[\sum_{j=1}^K V_j^2 \Pi_{2j} \right]^2}{\left[\sum_{j=1}^K \frac{V_j^2}{(D_j + \lambda)^2} \right]^{3/2} \left[\prod_{j=1}^K (D_j + \lambda)^2 \right] (\underline{g}^T \underline{g})^{1/2}}$$

$$\text{这里 } \Pi_{1j} = \prod_{i=1, i \neq j}^K (D_i + \lambda), \quad \Pi_{2j} = \prod_{i=1, i \neq j}^K (D_i + \lambda)^2, \quad \Pi_{3j} = \prod_{i=1, i \neq j}^K (D_i + \lambda)^3.$$

(24) 的分母是正的, 因为每个因子都是正的. 因此 $\frac{d \cos \gamma}{d\lambda}$ 的

符号决定于其分子的符号. 注意到 $\Pi_{1j} \Pi_{3j} = (\Pi_{2j})^2$, 上式的

分子可写成

$$(26) \quad \left[\sum_{j=1}^k (v_j \pi_{ij}^{\frac{1}{2}})^2 \right] \left[\sum_{j=1}^k (v_j \pi_{ij}^{\frac{1}{2}})^2 \right] - \left[\sum_{j=1}^k (v_j \pi_{ij}^{\frac{1}{2}}) (v_j \pi_{ij}^{\frac{1}{2}}) \right]^2$$

由柯西不等式, (26) 为正, 故 $\frac{d \cos \gamma}{d \lambda}$ 恒为正 ($\lambda > 0$), 于是 γ 是 λ 的单调递减函数。

对于非常大的 λ 值, 矩阵 $(A + \lambda I)$ 由其对称阵 λI 所控制, 因此, 从 (10) 可看出当 $\lambda \rightarrow \infty$ 时, $\sigma_0 \rightarrow \rho/\lambda$, 从而在极限状态时, σ_0 与 ρ 成比例, 所以它们之间的夹角趋于零。另一方面, 若在 (10) 中, $\lambda = 0$ 则 (除 A 是对角阵矩阵这种明显的情况外) 向量 \underline{d}_j 与 $\underline{\rho}$ 交成一个有限的角, $0 < \gamma < \pi/2$ 。因此 γ 是 λ 的这样连续单调递减函数, 当 $\lambda \rightarrow \infty$ 时, $\gamma \rightarrow 0$ 。

量测的变尺度 方程组 (6) 的解 \underline{d}_0 的有关性质对于 b — 空间中线性变换是不变的。可是人所熟知, [3] 科曼法不具有尺度不变性, 故有必要按某种方式改变 b — 空间的尺度。我们选取导数 $\frac{\partial f_i}{\partial b_j}$ 在所有数据点 $i = 1, 2, \dots, n$ 的标准差作为 b — 空间的尺度单位, 由于这些导数一般是依赖于 b_j 本身, 因而 b_j 的现有试探值就得用来计算导数, 这样选择的尺度会使矩阵 A 变换成 $\frac{\partial f_i}{\partial b_j}$ 的相关系数矩阵。事实上, 这样选择尺度在线性最小平方问题中已经广泛地使用, 作为改进数值计算过程的一种手段。

因此, 我们定义变尺度后的矩阵 A^* 与变尺度后的向量 $\underline{\rho}^*$:

$$(27) \quad A^* = (a_{ij}^*) = \left(\frac{a_{ij}}{\sqrt{a_{jj}} \sqrt{a_{jj}'}} \right)$$

$$(28) \quad \underline{\rho}^* = (\rho_j^*) = \left(\frac{\rho_j}{\sqrt{a_{jj}}} \right)$$

并由

$$(29) \quad \underline{A}^* \underline{d}_t^* = \underline{g}^*$$

解出台劳级数方法的校正向量，于是得

$$(30) \quad \underline{d}_j = \underline{d}_j^* / \sqrt{a_{jj}}$$

算法的构造 适用的算法的大概轮廓现在已经明显了。

确定地说，对于第 γ 次迭代，造方程

$$(31) \quad (\underline{A}^{*(\gamma)} + \lambda^{(\gamma)} \underline{I}) \underline{d}^{*(\gamma)} = \underline{g}^{*(\gamma)}$$

由此方程，解出 $\underline{d}^{*(\gamma)}$ 。方程 (30) 可用以求 $\underline{d}^{(\gamma)}$ ，新试探向量

$$(32) \quad \underline{b}^{(\gamma+1)} = \underline{b}^{(\gamma)} + \underline{d}^{(\gamma)}$$

给出新平方和 $\underline{\pi}^{(\gamma+1)}$ 。要紧的是要这样选择 $\lambda^{(\gamma)}$ 使得

$$(33) \quad \underline{\pi}^{(\gamma+1)} < \underline{\pi}^{(\gamma)}$$

从前理论，显然恒存在一个充分大的 $\lambda^{(\gamma)}$ 使得 (33) 成立，除非 $\underline{b}^{(\gamma)}$ 已经到达 $\underline{\pi}$ 的极小点。因此需要某种形式的试错方法求出 $\lambda^{(\gamma)}$ ，使得 (33) 成立并使算法迅速地收敛于最小平方值。

在每次迭代中，我们都要求在 (近似的) 最大邻域中 $\underline{\pi}$ 为最小，在此最大邻域中，线性函数就给出非线性函数的合适的表示。因此，选择 $\lambda^{(\gamma)}$ 的策略总是要求用很小的 $\lambda^{(\gamma)}$ 值，每当未改进的台劳级数方法收使得很好的这种情况时。这在收敛过程的靠后阶段是特别有关系的，当猜测是在极小点的极邻近处进行时，这里 $\underline{\pi}$ 的等值面渐近于椭球面，模型的线性展开必须在非常小的区域内才是一个好的近似。因此只有当必须满足 (33) 时才用大的 $\lambda^{(\gamma)}$ 值。假使 $\underline{\pi}^{(\gamma+1)}$ 作为 λ 的函数，的确有一

个极小值，而且在第 r 次迭代中，选择与这极小值相应的 λ 值，使 $(\bar{z}^{(r)} - \bar{z}^{(r+1)})$ 为极大，那末这个局部最优选择对于大范围来说并不是好的策略，因为这实质上要求 λ 比为了满足 (2.3) 所必要的大的值还要大。这样的策略会保留最速下降法的许多性质，比如，开头很快地前进，跟着就越来越慢了。

因此我们应规定如下的策略：

设 $\nu > 1$

令 $\lambda^{(r-1)}$ 表示由前一次迭代算出的 λ 值

计算 $\bar{z}(\lambda^{(r-1)})$ 与注 2 $\bar{z}(\lambda^{(r-1)}/\nu)$

i) 如果 $\bar{z}(\lambda^{(r-1)}/\nu) \leq \bar{z}^{(r)}$ ，则令 $\lambda^{(r)} = \lambda^{(r-1)}/\nu$

ii) 如果 $\bar{z}(\lambda^{(r-1)}/\nu) > \bar{z}^{(r)}$ ， $\bar{z}(\lambda^{(r-1)}) \leq \bar{z}^{(r)}$ ，则令 $\lambda^{(r)} = \lambda^{(r-1)}$

iii) 如果 $\bar{z}(\lambda^{(r-1)}/\nu) > \bar{z}^{(r)}$ ， $\bar{z}(\lambda^{(r-1)}) > \bar{z}^{(r)}$ ，则继续注 2 乘以 ν 来加大 λ 一直到对于某个最小的正整数 w 使得 $\bar{z}(\lambda^{(r-1)}\nu^w) \leq \bar{z}^{(r)}$ 为止，这时，令 $\lambda^{(r)} = \lambda^{(r-1)}\nu^w$

由这种算法，我们常得到一个可使用的邻域；而且除一个由 ν 决定的因子外，我们几乎经常得到最大邻域，在其中台劳级数就给出符合我们目的的一个合适的表示，当 $\frac{|\lambda_j^{(r)}|}{2 + |\lambda_j^{(r)}|} < \varepsilon$ ，对一切 j ，某个恰当小的 $\varepsilon > 0$ ，比如说 10^{-5} ，与某个恰当的 ν ，比如说 10^{-3} 成立时，迭代收敛。 ν 的选择是任意的；取 $\nu = 10$ 经实践证实是一个好的选择。

注 2 如果 $\lambda^{(r-1)}$ 按有效数字个数与 1.0 比较已可忽略的话，则可立即进行检验 ii) 或 iii)，不必计算 $\bar{z}(\lambda^{(r-1)}/\nu)$ ，并省去含有 $\bar{z}(\lambda^{(r-1)}/\nu)$ 的比较。

注 3 遇到这样的问题，参数估计的相关系数是极高的 (> 0.99)。

确定地说, 情况 *iii*, 只是少见的。因此, 在每次迭代中, 常常要用两个 $\lambda^{(r)}$ 的值来解 (31)。其中一个解是为了标准的白劳级数方法所需要的, 多余的一个解一般所需要的计算量比计算 A^* 的计算量少, 所以每次迭代中, 小比例的增加计算量会在迭代功效方面得到更加的补偿。

可能还要注意, 当用浮点算术时, 在单精度计算 \hat{y}_i 后, 常常可望双精度累积 (3) 式的平方和 (为了检验 i 与 ii 之用) 做不到这一点则在极小点附近, 单凭捨入误差就会导致至的错误性质。将 λ 加到 A^* 的对角线元素上去, 这在数值计算上的必然便利就是合成矩阵 $(A^* + \lambda I)$ 常常比 A^* 本身具有较好的制约性 [译者注: 即从矩阵的病态的角度来说], 这会出现 λ 增大到不合理的大值。在这种情况下, 修改检验 *iii*, 会有帮助的。这样修改检验:

$$\text{设 } \underline{b}^{(r+1)} = \underline{b}^{(r)} + K^{(r)} \underline{d}^{(r)}, \quad K^{(r)} \leq 1$$

注意到角 $\gamma^{(r)}$ 是 $\lambda^{(r)}$ 的递减函数, 选择一个准则角 $\gamma_0 < \pi/2$, 并取

$$K^{(r)} = 1, \text{ 若 } \gamma^{(r)} \geq \gamma_0.$$

如果 $\lambda^{(r)}$ 已增大到使 $\gamma^{(r)} < \gamma_0$, 而检验 *iii* 还不能通过的话, 则不再加大 $\lambda^{(r)}$, 而是选取充分小的 $K^{(r)}$ 使 $\underline{b}^{(r+1)} < \underline{b}^{(r)}$ 。这是可以做到的, 因为 $\gamma^{(r)} < \gamma_0 < \pi/2$, 合适的准则角选为 $\gamma_0 = \pi/4$ 。

可能还要注意, 当 $\lambda = 0$ 时, $\cos \gamma$ 为正只有当 A 是正定时才能保证到。在出现极高的相关系数时, 矩阵 A 的正定性单凭捨入误差就能被破坏。在这种情况下, 无论用什么值 $K^{(r)}$, 白劳级数方法都会发散。现在描述的算法, 由于用了 $(A + \lambda I)$,

所以纵然 A 可能不是十分正定的，也能保证 $\cos \gamma$ 为正。虽然为非线性模型取数据时，不一定就能预见参数估计具有很高的相关系数，不过较好的实验设计常能真正地减小这些极端的相关系数，当它们出现的时候。

对于其它问题的应用 显然所描述的方法也能用到其它类型的问题上去。例如，可以在解非线性代数方程组的斜量法与牛顿—拉甫孙方法之间进行内插，应用隐方法解非线性边值问题所关联的非线性差分联立方程。总之，这样的问题都是最小平方估计问题在 $n = k$ 时的特殊情况。设待解的方程组能写成

$$(34) \quad 0 = f_i(\underline{x}) \quad i = 1, 2, \dots, k,$$

这里 \underline{x} 是未知量 x_j 的 k 维向量

对于斜量法，习惯上定义一个误差准则

$$(35) \quad \Phi = \sum_{i=1}^k [f_i(\underline{x})]^2$$

并沿着由

$$(36) \quad -\left(\frac{\partial \Phi}{\partial x_j}\right) = -\left(2 \sum_{i=1}^k f_i \frac{\partial f_i}{\partial x_j}\right)$$

定义的 Φ 的负梯度方向上移动来校正试探向量 $\underline{x}^{(v)}$ 。

于是

$$(37) \quad x_j^{(v+1)} = x_j^{(v)} + d_j^{(v)}, \quad j = 1, 2, \dots, k,$$

这里

$$(38) \quad d_j^{(v)} = -a \frac{\partial \Phi}{\partial x_j}, \quad j = 1, 2, \dots, k,$$

a 是一个恰当定义的常数：

用矩阵记号，则有

$$(39) \quad \left(\frac{1}{a} \mathbf{I}\right) \underline{f}^{(r)} = \underline{g}^{(r)}.$$

另一方面，牛顿—拉周孙方法，它包含 f_i 的台劳级数展开式的一次项，给出方程

$$(40) \quad \sum_{j=1}^K \left(\frac{\partial f_i}{\partial x_j}\right)^{(r)} f_j^{(r)} = -f_i^{(r)}, \quad i=1, 2, \dots, K.$$

用矩阵记号，则有

$$(41) \quad \underline{B} \underline{f}_t = \underline{f},$$

这里矩阵 $\underline{B} = -\left(\frac{\partial f_i}{\partial x_j}\right)$ 一般不是对称的。将 (41) 左乘以 \underline{B}^T 形

成 $\underline{B}^T \underline{B} = \underline{A}$ ， $\underline{B}^T \underline{f} = \underline{g}$ 。矩阵 \underline{A} 是对称的。于是矩阵 \underline{A} 与向量 \underline{g} 分别规范化为 \underline{A}^* 与 \underline{g}^*

应用这新算法，则形成方程组

$$(42) \quad (\underline{A}^* + \lambda^{(r)} \mathbf{I}) \underline{f}^{*(r)} = \underline{g}^*$$

这与非线性最小平方估计问题所形成的方程组完全一样。求解的计算方法也完全一样。不过，除输入误差而外， \underline{w} 的最小值已知是零。

结 论 所描述的算法分担着斜量法的能力，即能从一个初始值收敛，而这个初始值可能是在其它方法的收敛域之外。这个方法又分担着台劳级数方法的能力，即当进入收敛值的邻

域后，就能迅速地接近收敛值。因此这个方法兼有以前两个方法的最优点，同时又避免了它们的严重的限制性。

计算机程序 Fortrain 程序“Least - Squares Estimation of Nonlinear Parameters”实现了本文中的算法，作为 IBM 分程序 No 1428 采用。