

递归最小二乘法

Dezeming Family

2021 年 5 月 15 日

DezemingFamily 系列书和小册子因为是电子书，所以可以很方便地进行修改和重新发布。如果您获得了 DezemingFamily 的系列书，可以从我们的网站 [<https://dezeming.top/>] 找到最新版。对书的内容建议和出现的错误欢迎在网站留言。

20210721：完成第一版。虽然 5 月份就想写了，但因为科研任务较重，所以一直推迟到了 7 月中旬。

目录

一 介绍	1
二 加权最小二乘法简介	1
三 递归最小二乘法的基本思想	2
四 递归最小二乘法的详细推导	2
五 递归最小二乘法的使用步骤	4
参考文献	4

一 介绍

关于最小二乘法已经在 DezemingFamily 的《最小二乘法》中进行了讲解。为了保证读者阅读方便，我们还是使用《最小二乘法》中定义的符号。

但是很多时候最小二乘法并不能很好应用，因为存在以下情况：

- 当估计值与真实值相差很大时，应该降低对估计结果的影响，而估计值与真实值相差很小时，应该提高对估计结果的影响。
- 当有新样本被添加进来以后，最好不要重新计算整个逆再重新求权重参数，而是可以进行迭代地计算和更新权重参数。

解决第一个问题的方法被称为加权最小二乘法，解决第二个问题的方法被称为递归最小二乘法。

二 加权最小二乘法简介

我们在《最小二乘法》中已知：

$$e = \vec{e}^T \vec{e} = (\vec{b} - A\vec{x}^*)^T (\vec{b} - A\vec{x}^*) \quad (二.1)$$

$$\vec{x}^* = (A^T A)^{-1} A^T \vec{b} \quad (二.2)$$

其中， e 表示误差， A 表示样本参数矩阵， \vec{x}^* 表示待估计样本权重。

加权最小二乘估计的表示为 e 加一个误差权重矩阵：

$$e = \vec{e}^T W \vec{e} = (\vec{b} - A \vec{x}^*)^T W (\vec{b} - A \vec{x}^*) \quad (二.3)$$

采用矩阵求导可得（见 DezemingFamily 的《矩阵导数》）：

$$\vec{x}^* = (A^T W A)^{-1} A^T W \vec{b} \quad (二.4)$$

分析一下误差权重矩阵，我们完全可以让误差权重矩阵 W 为一个对角矩阵，对角线上的元素 $a_{i,i}$ 就相当于为第 i 个样本加权。但其实在实际运算中我们可以求比较理想的 W 误差权重矩阵。

下面讲解一种计算误差权重的方法：

- 先使用普通的最小二乘法，计算得到样本权重 \vec{x}^* 。
- 使用重新计算估计样本值与实际样本值之间的误差。
- 用第 i 个样本的误差的绝对值取倒数，作为误差权重 W 的对角线第 i 个元素值。

至于什么线性无偏最小方差估计（马尔科夫估计）这里就先不提了，我会放在《加权最小二乘法-马尔科夫估计》，是具有一定理论依据的误差权重生成方法。

注意加权最小二乘法还有一些应用，例如我们企图让近期的数据权重更大，远期的数据权重更小，这个时候也可以使用加权最小二乘法，对角线上的元素可以从上往下依次递减。

三 递归最小二乘法的基本思想

不论是递归最小二乘还是加权递归最小二乘，都需要获得全部测量值才能计算，非常不方便。有些时候，我们会获得成千上万的数据，对这些数据的矩阵运算量非常巨大。

递归最小二乘法则是可以将数据一个一个送入，然后不断根据新数据来更新模型；或者可以一批一批送入然后更新模型。这个思想可以参考求平均值的过程，如果我们已经有了前 k 个数据的平均值 \vec{a}_k ，又来了一个新的数据 a_{k+1} ，应该怎么得到这 $k+1$ 个数据的平均值呢？其实很简单：

$$\vec{a}_{k+1} = \frac{\vec{a}_k \times k + a_{k+1}}{k+1} \quad (三.1)$$

$$= \frac{\vec{a}_k \times (k+1) + a_{k+1} - \vec{a}_k}{k+1} \quad (三.2)$$

$$= \vec{a}_k + \frac{a_{k+1} - \vec{a}_k}{k+1} \quad (三.3)$$

将新添加的数据根据公式三.3计算生成新的平均数即可。

四 递归最小二乘法的详细推导

有人觉得递归最小二乘法的推导比较复杂所以选择了跳过，其实它的推导过程挺简单的，只是我们需要记好这些矩阵和向量及其转置的形式。

假如我们进行了 k 次估计，得到：

$$\vec{b}'_k = A_k \vec{x}_k^* \quad (四.1)$$

$$e_k = (\vec{b}_k - \vec{b}'_k)^T (\vec{b}_k - \vec{b}'_k) \quad (四.2)$$

其中， \vec{b}_k 表示样本实际值构成的向量， \vec{b}'_k 表示样本估计值构成的向量； \vec{x}_k^* 表示我们 k 次估计得到的权重向量。

我们的目标是，希望第 k 次得到的权重估计为上一次估计的权重与当前测量误差的线性组合：

$$\vec{x}_k^* = \vec{x}_{k-1}^* + K(\vec{b}_k - A_k \vec{x}_{k-1}^*) \quad (四.3)$$

现在开始正式推导。根据最小二乘法，我们知道 \vec{x}_k^* 的计算公式是：

$$\vec{x}_k^* = (A_k^T A_k)^{-1} A_k^T \vec{b}_k \quad (四.4)$$

这里的 \vec{b}_k 表示 k 个观测值构成的向量。

我们将上式拆成两部分： $(A_k^T A_k)^{-1}$ 和 $A_k^T \vec{b}_k$ 。

递推一

设 $P_k^{-1} = A_k^T A_k$ ，我们再重新定义一下数据格式，设样本一共 t 个特征，第 i 个样本表示为：

$$b_i = \begin{bmatrix} a_{i,1} & a_{i,2} & \dots & a_{i,t} \end{bmatrix} \begin{bmatrix} x_1^* \\ x_2^* \\ \dots \\ x_t^* \end{bmatrix} = \vec{a}_i^T \vec{x}_k^* \quad (四.5)$$

设样本特征构成的矩阵 A_k 为：

$$A_k = \begin{bmatrix} \vec{a}_1^T \\ \vec{a}_2^T \\ \dots \\ \vec{a}_k^T \end{bmatrix} \quad (四.6)$$

注意这里 \vec{a}_i 表示的是第 i 个样本的特征构成的向量，而《最小二乘法》中 \vec{a}_i 定义的是所有样本的第 i 个特征构成的向量，虽然表示不同，但构成的矩阵 A 是一样的。

因此：

$$P_k^{-1} = A_k^T A_k \quad (四.7)$$

$$= \begin{bmatrix} \vec{a}_1 & \vec{a}_2 & \dots & \vec{a}_k \end{bmatrix} \begin{bmatrix} \vec{a}_1^T \\ \vec{a}_2^T \\ \dots \\ \vec{a}_k^T \end{bmatrix} \quad (四.8)$$

$$= \sum_{i=1}^k \vec{a}_i \vec{a}_i^T = \sum_{i=1}^{k-1} \vec{a}_i \vec{a}_i^T + \vec{a}_k \vec{a}_k^T \quad (四.9)$$

$$= P_{k-1}^{-1} + \vec{a}_k \vec{a}_k^T \quad (四.10)$$

递推二

我们再看一下 $A_k^T \vec{b}_k$ ：

$$A_k^T \vec{b}_k = \begin{bmatrix} \vec{a}_1 & \vec{a}_2 & \dots & \vec{a}_k \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \dots \\ b_k \end{bmatrix} \quad (四.11)$$

$$= \sum_{i=1}^k \vec{a}_i b_i = \sum_{i=1}^{k-1} \vec{a}_i b_i + \vec{a}_k b_k \quad (四.12)$$

$$= A_{k-1}^T \vec{b}_{k-1} + \vec{a}_k b_k \quad (四.13)$$

有了上述两个递推式，我们就可以继续向下推导了。

我们把当前的已知公式列出：

$$\vec{x}_k^* = (A_k^T A_k)^{-1} A_k^T \vec{b}_k \quad (四.14)$$

$$A_k^T A_k = A_{k-1}^T A_{k-1} + \vec{a}_k \vec{a}_k^T \quad (四.15)$$

$$A_k^T \vec{b}_k = A_{k-1}^T \vec{b}_{k-1} + \vec{a}_k b_k \quad (四.16)$$

因此：

$$\vec{x}_k^* = (A_k^T A_k)^{-1} A_k^T \vec{b}_k = P_k A_k^T \vec{b}_k = P_k (A_{k-1}^T \vec{b}_{k-1} + \vec{a}_k b_k) \quad (四.17)$$

又因为：

$$\vec{x}_{k-1}^* = P_{k-1} A_{k-1}^T \vec{b}_{k-1} \quad (四.18)$$

$$P_{k-1}^{-1} \vec{x}_{k-1}^* = A_{k-1}^T \vec{b}_{k-1} \quad (四.19)$$

因此可以得到：

$$\vec{x}_k^* = P_k (A_{k-1}^T \vec{b}_{k-1} + \vec{a}_k y_k) = P_k (P_{k-1}^{-1} \vec{x}_{k-1}^* + \vec{a}_k y_k) \quad (四.20)$$

$$= P_k \left((P_k^{-1} - \vec{a}_k \vec{a}_k^T) \vec{x}_{k-1}^* + \vec{a}_k b_k \right) \quad (四.21)$$

$$= \vec{x}_{k-1}^* + P_k \vec{a}_k (b_k - \vec{a}_k^T \vec{x}_{k-1}^*) \quad (四.22)$$

因此我们就得到了根据 \vec{x}_{k-1}^* 和新的样本来更新得到 \vec{x}_k^* 的形式。

五 递归最小二乘法的使用步骤

我们定义一些符号来描述这个过程：

$$\varepsilon_k = b_k - \vec{a}_k^T \vec{x}_{k-1}^* \quad (五.1)$$

$$K_k = P_k \vec{a}_k \quad (五.2)$$

$$P_k = (P_{k-1}^{-1} + \vec{a}_k \vec{a}_k^T)^{-1} \quad (五.3)$$

$$\vec{x}_k^* = \vec{x}_{k-1}^* + K_k \varepsilon_k \quad (五.4)$$

尽管 $P_{k-1}^{-1} + \vec{a}_k \vec{a}_k^T$ 只是 $k \times k$ 的矩阵，但是求逆也不是那么方便，而我们有新的方法，首先大家需要知道一个定理，当矩阵 A 、 C 和 BCD 都是可逆矩阵时，则：

$$[A + BCD]^{-1} = A^{-1} - A^{-1}B[C^{-1} + DA^{-1}B]^{-1}DA^{-1} \quad (五.5)$$

我们令 $A = P_{k-1}^{-1}$ ， $C = E$ ， $B = \vec{a}_k$ ， $D = \vec{a}_k^T$ ，代入上式之后，推导出得到 P_k^{-1} 的公式：

$$P_k = P_{k-1} - \frac{P_{k-1} \vec{a}_k \vec{a}_k^T P_{k-1}}{1 + \vec{a}_k^T P_{k-1} \vec{a}_k} \quad (五.6)$$

这样我们就不需要求逆了！

因此，最终递归最小二乘法的使用步骤是：

$$\varepsilon_k = b_k - \vec{a}_k^T \vec{x}_{k-1}^* \quad (五.7)$$

$$K_k = P_k \vec{a}_k \quad (五.8)$$

$$P_k = P_{k-1} - \frac{P_{k-1} \vec{a}_k \vec{a}_k^T P_{k-1}}{1 + \vec{a}_k^T P_{k-1} \vec{a}_k} \quad (五.9)$$

$$\vec{x}_k^* = \vec{x}_{k-1}^* + K_k \varepsilon_k \quad (五.10)$$

参考文献

- [1] https://blog.csdn.net/weixin_38898944/article/details/
- [2] <https://zhuanlan.zhihu.com/p/59532437>
- [3] <https://zhuanlan.zhihu.com/p/53883828>
- [4] https://blog.csdn.net/weixin_45072297/article/details/
- [5] <http://www.personal.reading.ac.uk/sis01xh/>