

# 欧氏平面上平方距离最小的直线拟合

BY JIN

2019-06-10

## 摘要

从平面上的一族点拟合一条直线是一个常见问题。然而统计上常用的针对 $y = kx + b$ 的最小二乘优化 $\{k = (n\sum xy - \sum x\sum y) / (n\sum x^2 - (\sum x)^2) = \text{cov}(x, y) / \text{cov}(x, x), b = (\sum y - k\sum x) / n = \bar{y} - k\bar{x}\}$ ，最小化的是 $y$ 方向上的误差 $\sum (y_i - kx_i - b)^2$ ，并不是欧几里德平面上的距离最小。本文将针对点到直线的垂直距离，使用完全最小二乘法求最优，得出更为优雅的结果，并自多种角度对这一结果进行解释和验证。

## 1 问题描述

待拟合的直线用法向式表示为

$$x \cos\alpha + y \sin\alpha - r = 0 \quad (1)$$

则任意一点 $(x, y)$ 到该直线的距离为

$$d = |x \cos\alpha + y \sin\alpha - r| \quad (2)$$

则问题是对已知点集 $\{(x, y)\}_n$ ，以最小化 $F(\alpha, r) = \sum d^2$ 为目标，求最优解

$$\text{ArgMin}_{\alpha, r} \sum_i (x_i \cos\alpha + y_i \sin\alpha - r)^2 \quad (3)$$

## 2 求解最优

记 $\cos\alpha = c, \sin\alpha = s$ ，待优化的和式有如下展开

$$\begin{aligned} F(\alpha, r) &= \sum (x \cos\alpha + y \sin\alpha - r)^2 \\ &= \sum (c^2 x^2 + s^2 y^2 + 2csxy - 2rcx - 2rsy + r^2) \\ &= c^2 \sum x^2 + s^2 \sum y^2 + 2cs \sum xy - 2rc \sum x - 2rs \sum y + nr^2 \end{aligned} \quad (4)$$

求偏导，有

$$\begin{aligned} 0 = \frac{\partial F}{\partial r} &= -2(c \sum x + s \sum y - nr) \\ \text{即 } r &= (c \sum x + s \sum y) / n = c\bar{x} + s\bar{y} \end{aligned} \quad (5)$$

以及

$$\begin{aligned} 0 = \frac{\partial F}{\partial \alpha} &= -2(cs(\sum x^2 - \sum y^2) - (c^2 - s^2)\sum xy - r(s\sum x - c\sum y)) \\ \text{代入 } r, \quad 0 &= cs(\bar{x}^2 - \bar{y}^2) - (c^2 - s^2)\bar{x}\bar{y} - (c\bar{x} + s\bar{y})(s\bar{x} - c\bar{y}) \\ &= cs(\bar{x}^2 - \bar{y}^2) - (c^2 - s^2)\bar{x}\bar{y} - cs(\bar{x}^2 - \bar{y}^2) + (c^2 - s^2)\bar{x}\bar{y} \\ &= cs(\text{cov}(x, x) - \text{cov}(y, y)) - (c^2 - s^2)\text{cov}(x, y) \end{aligned} \quad (6)$$

整理，得

$$\frac{2 \text{cov}(x, y)}{\text{cov}(x, x) - \text{cov}(y, y)} = \frac{2 \cos\alpha \sin\alpha}{\cos^2\alpha - \sin^2\alpha} = \tan 2\alpha \quad (7)$$

由此解出

$$\alpha = \frac{1}{2} \arctan \frac{2 \operatorname{cov}(x, y)}{\operatorname{cov}(x, x) - \operatorname{cov}(y, y)} + \frac{k\pi}{2} \quad (8)$$

包含相垂直的两个解，正好对应直线的方向向量 $\theta$ 和法向量方向 $\alpha$ ，也是误差函数的最大和最小值。

### 3 分析验根

统计角度上看， $\operatorname{cov}(x, x) - \operatorname{cov}(y, y)$ 的符号表示点集在 $x, y$ 方向上的分散程度大小，而 $\operatorname{cov}(x, y)$ 的符号表示了点集中 $x, y$ 是正相关还是负相关：据此可以确定 $\alpha$ 的正确取值。

1. 当 $\operatorname{cov}(x, x) - \operatorname{cov}(y, y) > 0, \operatorname{cov}(x, y) > 0$ ，对应 $0 < \theta < \frac{\pi}{4}, -\frac{\pi}{2} < \alpha < -\frac{\pi}{4}$ ，因此

$$\begin{aligned} \theta &= \frac{1}{2} \arctan 2(2 \operatorname{cov}(x, y), \operatorname{cov}(x, x) - \operatorname{cov}(y, y)) \\ \alpha = \theta \pm \frac{\pi}{2} &= \frac{1}{2} \arctan 2(-2 \operatorname{cov}(x, y), \operatorname{cov}(y, y) - \operatorname{cov}(x, x)) \end{aligned}$$

2. 当 $\operatorname{cov}(x, x) - \operatorname{cov}(y, y) < 0, \operatorname{cov}(x, y) > 0$ ，对应 $\frac{\pi}{4} < \theta < \frac{\pi}{2}, -\frac{\pi}{4} < \alpha < 0$ ，因此仍有

$$\begin{aligned} \theta &= \frac{1}{2} \arctan 2(2 \operatorname{cov}(x, y), \operatorname{cov}(x, x) - \operatorname{cov}(y, y)) \\ \alpha = \theta \pm \frac{\pi}{2} &= \frac{1}{2} \arctan 2(-2 \operatorname{cov}(x, y), \operatorname{cov}(y, y) - \operatorname{cov}(x, x)) \end{aligned}$$

3. 同理（或由连续性）可证 $\operatorname{cov}(x, x) - \operatorname{cov}(y, y) < 0, \operatorname{cov}(x, y) < 0, -\frac{\pi}{2} < \theta < -\frac{\pi}{4}, 0 < \alpha < \frac{\pi}{4}$ 的情况，以及 $\operatorname{cov}(x, x) - \operatorname{cov}(y, y) > 0, \operatorname{cov}(x, y) < 0, -\frac{\pi}{4} < \theta < 0, \frac{\pi}{4} < \alpha < \frac{\pi}{2}$ 的情况也有同样的结论

因此统一地，有结论

$$\alpha = \frac{1}{2} \arctan 2(-2 \operatorname{cov}(x, y), \operatorname{cov}(y, y) - \operatorname{cov}(x, x)) \quad (9)$$

### 4 统计角度

按 $r = \bar{x} \cos \alpha + \bar{y} \sin \alpha$ ，若对点集 $X = \begin{bmatrix} \vdots & \vdots \\ x_i & y_i \\ \vdots & \vdots \end{bmatrix}_{n \times 2}$ 作平移变换 $X' = X - \bar{X}$ ，可将直线方程写成齐次形式：

$$x' \cos \alpha + y' \sin \alpha = 0 \quad (10)$$

再进行旋转变换 $X'' = X' R$ ， $R R^T = I$ ，此时新的协方差矩阵

$$\begin{aligned} \Sigma(X'') &= E((X'R - 0)^T (X'R - 0)) = R^T E(X'^T X') R \\ &= R^{-1} E((X - \bar{X})^T (X - \bar{X})) R \\ &= R^{-1} \Sigma(X) R \end{aligned} \quad (11)$$

为原协方差矩阵的一个相似变换。

由 $X''$ 为对称正定矩阵，故必存在恰当的正交变换 $R$ 使其对角化，即

$$C(X'') = \begin{bmatrix} \sigma_{x''}^2 & 0 \\ 0 & \sigma_{y''}^2 \end{bmatrix} \quad (12)$$

如此可将点集的误差分解到彼此独立且正交的两个方向上。设 $\sigma_{x''}^2 > \sigma_{y''}^2$ ，则 $\sigma_{x''}^2$ 对应了直线方向， $\sigma_{y''}^2$ 对应了直线的法线方向。由此引出算法：

1. 求点集 $\{(x, y)\}_n$ 的协方差矩阵 $C = \begin{bmatrix} \text{cov}(x, x) & \text{cov}(x, y) \\ \text{cov}(x, y) & \text{cov}(y, y) \end{bmatrix}$
2. 对 $C$ 作特征分解 $C = T\Sigma'T^{-1}$ ，其中 $C' = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}$ ， $\sigma_1^2 > \sigma_2^2$ ， $T = \begin{bmatrix} u & v \\ -v & u \end{bmatrix} = \begin{bmatrix} \cos\beta & \sin\beta \\ -\sin\beta & \cos\beta \end{bmatrix}$
3. 该特征分解对应了点集（围绕其均值）的一个旋转变换 $[x'', y''] = [x', y']T^{-1}$ ，该变换将直线的方向向量旋转到了0度。而反过来 $\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos\beta & -\sin\beta \\ \sin\beta & \cos\beta \end{bmatrix} \begin{bmatrix} x'' \\ y'' \end{bmatrix}$ 意味着 $X''$ 旋转 $-\beta$ 即可到达 $X'$ 的角度，因此直线方向为 $\theta = -\beta$ ，法向 $\alpha = \pi - \beta$ ，即 $\begin{bmatrix} \cos\alpha \\ \sin\alpha \end{bmatrix} = \begin{bmatrix} -\sin\theta \\ \cos\theta \end{bmatrix} = \begin{bmatrix} \sin\beta \\ \cos\beta \end{bmatrix} = \begin{bmatrix} v \\ u \end{bmatrix}$ 。

实践中，没有必要对 $X^T X$ 做特征分解，完全可以等效地对 $X$ 做奇异值分解：

## 5 完全最小二乘(SVD分解)

同样按(10)的方式齐次化直线方程。令 $X' = \begin{bmatrix} \vdots & \vdots \\ x'_i & y'_i \\ \vdots & \vdots \end{bmatrix}_{n \times 2}$ ， $A = \begin{bmatrix} \cos\alpha \\ \sin\alpha \end{bmatrix}$ ，此时优化目标可以写成

$$E(X) = (XA)^T(XA) = A^T X^T X A, \quad (13)$$

求 $A = \text{Argmin}_A E(X)$ 。对 $X$ 作SVD分解： $X = U_{n \times 2} \Sigma_{2 \times 2} V_2^T$

$$E(X) = A^T V \Sigma^T U^T U \Sigma V^T A = A^T V \Sigma^T \Sigma V^T A \quad (14)$$

设 $V = \begin{pmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{pmatrix}$ ， $\Sigma = \begin{pmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \end{pmatrix}$ ， $\sigma_1 \geq \sigma_2 \geq 0$ ，可直接求出

$$E(X) = \frac{1}{2}(\sigma_1^2 + \sigma_2^2 + (\sigma_1^2 - \sigma_2^2)\cos(2\alpha - 2\theta)) \quad (15)$$

当 $2(\alpha - \theta) = \pi + 2k\pi$ 即 $\alpha = \theta + \frac{\pi}{2} + k\pi$ 时取最小值。考虑到 $\alpha + \pi$ 仅仅是 $\alpha$ 的 $180^\circ$ 反方向，故只取一个解 $\alpha = \theta + \frac{\pi}{2}$ 即可。此时

$$A = \begin{bmatrix} \cos\alpha \\ \sin\alpha \end{bmatrix} = \begin{bmatrix} -\sin\theta \\ \cos\theta \end{bmatrix} = V \begin{bmatrix} 2 \\ 0 \end{bmatrix} \quad (16)$$

正好与特征分解算法的结果一致。

另一方面，按Total Least Squares求解，也能有：

$$A = \text{Argmin}_A \|\tilde{X}\|_F, \quad (X + \tilde{X})A = 0 \quad (17)$$

SVD分解

$$\begin{aligned} X &= [U_1 \ U_2] \begin{bmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \end{bmatrix} [V_1 \ V_2]^T \\ X + \tilde{X} &= [U_1 \ U_2] \begin{bmatrix} \sigma_1 & 0 \\ 0 & 0 \end{bmatrix} [V_1 \ V_2]^T = U_1 \sigma_1 V_1^T \\ \text{两式相减} \quad \tilde{X} &= -U_2 \sigma_2 V_2^T \end{aligned} \quad (18)$$

由此也有，在 $X + \tilde{X}$ 的补空间中取单位向量

$$A = \pm V_2$$

可满足 $(X + \tilde{X})A = U_1 \sigma_1 V_1^T \cdot V_2 = U_1 \sigma_1 (V_1^T V_2) = 0$ 。

Q.E.D.