

Foundations of Data Science

Statistical Analyses


尹一通、刘明谋 Nanjing University, 2024 Fall

方差分析

Analysis of Variance (ANOVA)



Ronald Fisher
(1890-1962)




Statistical Methods for Research Workers (1925)

析因设计 / 析因分析

Factorial design / Factorial analysis

- 多个因素会影响实验结果吗？
 - 独立性检验（列联表、Pearson卡方检验）
- 不同因素对实验结果的影响如何？是否存在“ $1+1>2$ ”的“化学反应”？
 - 析因设计、析因分析
- 方差分析（ANOVA）、回归分析（regression）



单因素方差分析

one-way / single-factor analysis of variance

- 单个因素的各个水平对实验结果的影响（是否一样？最好的？最差的？）
- 模型假设（ m 个水平，每个水平 n_i 次试验）
 - 正态性：水平 i 对结果的效应(effect)为 μ_i ，每次试验有噪声 $\epsilon_{ij} \sim N(0, \sigma_i^2)$
 - 方差齐性：噪声同分布 $\sigma_1^2 = \dots = \sigma_m^2 = \sigma^2$
 - 独立性：噪声之间相互独立
- 现实：不同实验对象特质不同，明显影响试验结果
 - 更大的样本量 + 随机分组，每一组整体看起来都差不多

All models are wrong,
but some are useful.

分析方差

- 总离差平方和 (Sum of Squares) : $SS_T = \sum_{i,j}(X_{ij} - \bar{X}_{..})^2$
 - 组内离差平方和 (误差平方和) : $SS_W = \sum_{i,j}(X_{ij} - \bar{X}_{i.})^2$
 - 组间离差平方和 (效应平方和) : $SS_B = \sum_{i,j}(\bar{X}_{i.} - \bar{X}_{..})^2$
- 直觉：效应 $\mu_i \approx$ 组内均值 $\bar{X}_{i.}$ ，如果效应有差距，组间离差平方和会较大
计算：
$$\begin{aligned}\mathbb{E}[SS_B] &= \mathbb{E}[\sum_i n_i \bar{X}_{i.}^2 - n \bar{X}_{..}^2] \\ &= \sum_i n_i [\text{Var}(\bar{X}_{i.}) + \mathbb{E}[\bar{X}_{i.}]^2] - n [\text{Var}(\bar{X}_{..}) + \mathbb{E}[\bar{X}_{..}]^2] \\ &= \sum_i n_i [\sigma^2/n_i + \mu_i^2] - n [\sigma^2/n + \bar{\mu}^2] \\ &= (m - 1)\sigma^2 + \sum_i n_i (\mu_i - \bar{\mu})^2\end{aligned}$$

分析方差

组间离差平方和

- 组间离差平方和: $SS_B = \sum_{i,j} (\bar{X}_{i.} - \bar{X}_{..})^2$

计算: $\mathbb{E}[SS_B] = \mathbb{E}[\sum_i n_i \bar{X}_{i.}^2 - n \bar{X}_{..}^2]$

$$= \sum_i n_i [\text{Var}(\bar{X}_{i.}) + \mathbb{E}[\bar{X}_{i.}]^2] - n [\text{Var}(\bar{X}_{..}) + \mathbb{E}[\bar{X}_{..}]^2]$$

$$= \sum_i n_i [\sigma^2/n_i + \mu_i] - n [\sigma^2/n + \bar{\mu}^2]$$

$$= (m-1)\sigma^2 + \sum_i n_i (\mu_i - \bar{\mu})^2$$

- 如果效应相同 $\mu_i = \bar{\mu}$, 组间离差平方和 $SS_B/(m-1)$ 是方差的无偏估计,

$$\text{且 } SS_B/\sigma^2 \sim \chi^2(m-1)$$

正态总体的样本方差的分布

• 若 $X_1, \dots, X_n \sim N(0,1)$, 则 $\sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi^2(n-1)$.

• **Proof:** 样本方差 $S^2 = \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{n-1}$. 注意到 $\sum_{i=1}^n (X_i - \bar{X})^2 = \sum_{i=1}^n X_i^2 - n\bar{X}^2$

又因为 $\bar{X} \sim N(0, 1/n)$, 所以 $\sqrt{n}\bar{X} \sim N(0,1)$, 且 $n\bar{X}^2 \sim \chi^2(1)$

改写 $\sum_{i=1}^n X_i^2 = (n-1)S^2 + n\bar{X}^2$, 记作 $\chi^2(n) = \underbrace{(n-1)S^2 + \chi^2(1)}_{\text{相互独立}}$

矩生成函数 (MGF): $M_{\chi_n^2}(t) = M_{(n-1)S^2}(t) \cdot M_{\chi_1^2}(t)$

卡方分布的矩生成函数是

$$M_{\chi_n^2}(t) = (1 - 2t)^{-n/2}$$

分析方差

组内离差平方和

- 组内离差平方和: $SS_W = \sum_{i,j} (X_{ij} - \bar{X}_{i.})^2$
 - $\sum_j (X_{ij} - \bar{X}_{i.})^2 / \sigma^2 \sim \chi^2(n_i - 1)$
 - $SS_W / \sigma^2 \sim \chi^2(n - m)$
- 如果效应相同 $\mu_i = \bar{\mu}$, $SS_B / (m - 1)$ 是方差的无偏估计, 且

$$SS_B / \sigma^2 \sim \chi^2(m - 1)$$

- F 检验?

正态总体的样本均值与样本方差

• 若 $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, 则 \bar{X} 与 S^2 相互独立。

• **Proof:** 严格一点: $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$, $\bar{X} - X_j = \frac{1}{n} \sum_{i \neq j} X_i - \frac{n-1}{n} X_j$

$$\bar{X} - X_j \sim N\left(\frac{(n-1)\mu}{n} - \frac{(n-1)\mu}{n}, (n-1)\frac{\sigma^2}{n^2} + (n-1)^2\frac{\sigma^2}{n^2}\right) = N\left(0, \frac{n-1}{n}\sigma^2\right)$$

两两之间的协方差: $\text{Cov}(\bar{X} - X_j, \bar{X}) = \text{Cov}(X_j, \bar{X}) - \text{Cov}(\bar{X}, \bar{X}) = \frac{\sigma^2}{n} - \frac{\sigma^2}{n} = 0$

$$\text{Cov}(X_j, X_j/n) = \sigma^2/n$$

两两独立不等于相互独立, 但在联合正态分布中意味着相互独立

假设检验

- 总离差平方和 (Sum of Squares) : $SS_T = \sum_{i,j}(X_{ij} - \bar{X}_{..})^2$
 - 组内离差平方和: $SS_W = \sum_{i,j}(X_{ij} - \bar{X}_{i.})^2$
 - 组间离差平方和: $SS_B = \sum_{i,j}(\bar{X}_{i.} - \bar{X}_{..})^2$
- 如果效应相同 $\mu_i = \bar{\mu}$, 组间离差平方和 $SS_B/(m - 1)$ 是方差的无偏估计,
且 $SS_B/\sigma^2 \sim \chi^2(m - 1)$
- 无关因素, 组内离差平方和 $SS_W/\sigma^2 \sim \chi^2(n - m)$
- F 检验: 如果效应相同 $\mu_i = \bar{\mu}$, $\frac{SS_B/(m - 1)}{SS_W/(n - m)} \sim F(m - 1, n - m)$

方差分析表

- 总离差平方和 (Sum of Squares) : $SS_T = \sum_{i,j}(X_{ij} - \bar{X}_{..})^2$
 - 组内离差平方和: $SS_W = \sum_{i,j}(X_{ij} - \bar{X}_{i.})^2$
 - 组间离差平方和: $SS_B = \sum_{i,j}(\bar{X}_{i.} - \bar{X}_{..})^2$
- F 检验: 如果效应相同 $\mu_i = \bar{\mu}$, $\frac{SS_B/(m-1)}{SS_W/(n-m)} \sim F(m-1, n-m)$

方差来源	平方和	自由度	均方(MS)	F比率
因素	SS (between)	m-1	SS(between) / (m-1)	$\frac{MS(\text{between})}{MS(\text{within})}$
误差	SS (within)	n-m	SS(within) / (n-m)	
总和	SS (total)	n-1		

快捷计算*

- 总离差平方和 (Sum of Squares) : $SS_T = \sum_{i,j}(X_{ij} - \bar{X}_{..})^2$
 - 组内离差平方和: $SS_W = \sum_{i,j}(X_{ij} - \bar{X}_{i.})^2$
 - 组间离差平方和: $SS_B = \sum_{i,j}(\bar{X}_{i.} - \bar{X}_{..})^2$
- F 检验: 如果效应相同 $\mu_i = \bar{\mu}$, $\frac{SS_B/(m-1)}{SS_W/(n-m)} \sim F(m-1, n-m)$
- 快捷计算: 令 $T_i = \sum_j X_{ij}$, $T = \sum_i T_i$
 - $SS_T = \sum_{i,j} X_{ij}^2 - T^2/n$, $SS_B = \sum_i T_i^2/n_i - T^2/n$, $SS_W = SS_T - SS_B$

参数估计

- 如果效应不同, 估计效应 μ_i : (最大似然估计)

$$L(\mu_1, \dots, \mu_m, \sigma^2) = \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left(- \sum_{i \leq m} \sum_{j \leq n_i} \frac{(X_{ij} - \mu_i)^2}{2\sigma^2} \right)$$

- 估计方差: 无关因素, 组内离差平方和 $SS_W / \sigma^2 \sim \chi^2(n - m)$

- 估计两个水平下的总体 $N(\mu_i, \sigma^2)$ 和 $N(\mu_j, \sigma^2)$ 的效应差 $\mu_i - \mu_j$

- $\mathbb{E}[\bar{X}_{i.} - \bar{X}_{j.}] = \mu_i - \mu_j$ 且 $\text{Var}(\bar{X}_{i.} - \bar{X}_{j.}) = \sigma^2(1/n_i + 1/n_j)$

- $$\frac{(\bar{X}_{i.} - \bar{X}_{j.}) - (\mu_i - \mu_j)}{\sigma \sqrt{1/n_i + 1/n_j}} \bigg/ \sqrt{\frac{SS_W}{\sigma^2} / (n - m)} = \frac{(\bar{X}_{i.} - \bar{X}_{j.}) - (\mu_i - \mu_j)}{\sqrt{SS_W(1/n_i + 1/n_j) / (n - m)}} \sim t(n - m)$$

双因素方差分析

two-way analysis of variance

- 两个因素的各个水平对实验结果的影响（是否一样？最好的？最差的？）
- 模型假设（ a 和 b 个水平，每个水平组合一次试验）
 - 线性： $X_{ij} = \mu + \alpha_i + \beta_j + \epsilon_{ij}$
 - 正态性：每次试验噪声 $\epsilon_{ij} \sim N(0, \sigma_i^2)$
 - 方差齐性：噪声同分布 $\sigma_1^2 = \dots = \sigma_m^2 = \sigma^2$
 - 独立性：噪声之间相互独立

All models are wrong,
but some are useful.

分析方差

- 总离差平方和: $SS_T = \sum_{i,j}(X_{ij} - \bar{X}_{..})^2$
 - 因素A的效应平方和: $SS_A = b \cdot \sum_{i \leq a}(\bar{X}_{i.} - \bar{X}_{..})^2$
 - 因素B的效应平方和: $SS_B = a \cdot \sum_{j \leq b}(\bar{X}_{.j} - \bar{X}_{..})^2$
 - 误差平方和: $SS_E = \sum_{i,j}(X_{ij} - \bar{X}_{i.} - \bar{X}_{.j} + \bar{X}_{..})^2$
- 直觉: 因素各水平的效应都相同的话 $\alpha_i = 0$ 或 $\beta_i = 0$, 效应平方和不会大
 - 如果因素A效应相同 $\alpha_i = 0$, $SS_A/\sigma^2 \sim \chi(a-1)$, 否则 $\mathbb{E}[SS_A/(a-1)] > \sigma^2$
 - 如果因素B效应相同 $\beta_i = 0$, $SS_B/\sigma^2 \sim \chi(b-1)$, 否则 $\mathbb{E}[SS_B/(b-1)] > \sigma^2$
- 无关因素, 误差平方和 $SS_E/\sigma^2 \sim \chi^2((a-1)(b-1))$

假设检验

- 直觉：因素各水平的效应都相同的话 $\alpha_i = 0$ 或 $\beta_i = 0$ ，效应平方和不会大
 - 如果因素A效应相同 $\alpha_i = 0$ ， $SS_A/\sigma^2 \sim \chi^2(a-1)$ ，否则 $\mathbb{E}[SS_A/(a-1)] > \sigma^2$
 - 如果因素B效应相同 $\beta_i = 0$ ， $SS_B/\sigma^2 \sim \chi^2(b-1)$ ，否则 $\mathbb{E}[SS_B/(b-1)] > \sigma^2$
- 无关因素，误差平方和 $SS_E/\sigma^2 \sim \chi^2((a-1)(b-1))$
- 检验因素A：
$$F_A = \frac{SS_A/(a-1)}{SS_E/[(a-1)(b-1)]}$$
- 检验因素B：
$$F_B = \frac{SS_B/(b-1)}{SS_E/[(a-1)(b-1)]}$$

双因素方差分析表

- 直觉：因素各水平的效应都相同的话 $\alpha_i = 0$ 或 $\beta_i = 0$ ，效应平方和不会大
 - 如果因素A效应相同 $\alpha_i = 0$ ， $SS_A/\sigma^2 \sim \chi(a-1)$ ，否则 $\mathbb{E}[SS_A/(a-1)] > \sigma^2$
 - 如果因素B效应相同 $\beta_i = 0$ ， $SS_B/\sigma^2 \sim \chi(b-1)$ ，否则 $\mathbb{E}[SS_B/(b-1)] > \sigma^2$
- 无关因素，误差平方和 $SS_E/\sigma^2 \sim \chi^2((a-1)(b-1))$

方差来源	平方和	自由度	均方(MS)	F比率
因素A	SS(A)	a-1	SS(A) / (a-1)	MS(A) / MS(E)
因素B	SS(B)	b-1	SS(B) / (b-1)	MS(A) / MS(E)
误差	SS(E)	(a-1)(b-1)	SS(E) / ((a-1)(b-1))	
总和	SS (total)	ab-1		

双因素方差分析和交互作用 (interaction)

two-way analysis of variance

- 两个因素的各个水平对实验结果的影响 (是否一样? 最好的? 最差的?)
- 模型假设 (a 和 b 个水平, 每个水平组合 c 次试验)
 - 线性: $X_{ij} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \epsilon_{ij}$
 - 正态性: 每次试验噪声 $\epsilon_{ij} \sim N(0, \sigma_i^2)$
 - 方差齐次性: 噪声同分布 $\sigma_1^2 = \dots = \sigma_m^2 = \sigma^2$
 - 独立性: 噪声之间相互独立

All models are wrong,
but some are useful.

分析方差

- 总离差平方和: $SS_T = \sum_{i,j,k} (X_{ijk} - \bar{X}_{...})^2$
 - 因素A的效应平方和: $SS_A = bc \cdot \sum_{i \leq a} (\bar{X}_{i..} - \bar{X}_{...})^2$
 - 因素B的效应平方和: $SS_B = ac \cdot \sum_{j \leq b} (\bar{X}_{.j.} - \bar{X}_{...})^2$
 - 交互作用的效应平方和: $SS_{AB} = c \cdot \sum_{i,j} (\bar{X}_{ij.} - \bar{X}_{i..} - \bar{X}_{.j.} + \bar{X}_{...})^2$
 - 误差平方和: $SS_E = \sum_{i,j,k} (X_{ijk} - \bar{X}_{ij.})^2$
- 直觉: 如果交互作用不存在, $\bar{X}_{ij.} \approx \bar{X}_{i..} + \bar{X}_{.j.} - \bar{X}_{...}$ 且 $\gamma_{ij} \approx 0$, 效应平方和不会大
 - 如果没有交互作用 $\gamma_{ij} = 0$, $SS_{AB}/\sigma^2 \sim \chi^2((a-1)(b-1))$, 否则
$$\mathbb{E}[SS_{AB}/(a-1)(b-1)] > \sigma^2$$
- 无关因素, 误差平方和 $SS_E/\sigma^2 \sim \chi^2(ab(c-1))$

假设检验

- 直觉：如果交互作用不存在 $\gamma_{ij} = 0$ ，效应平方和不会大
 - 如果没有交互作用 $\gamma_{ij} = 0$ ， $SS_{AB}/\sigma^2 \sim \chi^2((a-1)(b-1))$ ，否则
$$\mathbb{E}[SS_{AB}/(a-1)(b-1)] > \sigma^2$$
- 无关因素，误差平方和 $SS_E/\sigma^2 \sim \chi^2(ab(c-1))$
- 检验交互作用：
$$F_{AB} = \frac{SS_{AB}/[(a-1)(b-1)]}{SS_E/[ab(c-1)]} \sim F((a-1)(b-1), ab(c-1))$$

双因素方差分析表

- 直觉：如果交互作用不存在 $\gamma_{ij} = 0$ ，效应平方和不会大
 - 如果没有交互作用 $\gamma_{ij} = 0$ ， $SS_{AB}/\sigma^2 \sim \chi^2((a-1)(b-1))$ ，否则
$$\mathbb{E}[SS_{AB}/(a-1)(b-1)] > \sigma^2$$
- 无关因素，误差平方和 $SS_E/\sigma^2 \sim \chi^2(ab(c-1))$


方差来源	平方和	自由度	均方(MS)	F比率
因素A	SS(A)	a-1	SS(A) / (a-1)	MS(A) / MS(E)
因素B	SS(B)	b-1	SS(B) / (b-1)	MS(A) / MS(E)
交互作用	SS(AB)	(a-1)(b-1)	SS(AB) / ((a-1)(b-1))	MS(AB) / MS(E)
误差	SS(E)	ab(c-1)	SS(E) / (ab(c-1))	
总和	SS (total)	abc-1		

快捷计算*

- 总离差平方和： $SS_T = \sum_{i,j,k} (X_{ijk} - \bar{X}_{...})^2$
 - 因素A的效应平方和： $SS_A = bc \cdot \sum_{i \leq a} (\bar{X}_{i..} - \bar{X}_{...})^2$
 - 因素B的效应平方和： $SS_B = ac \cdot \sum_{j \leq b} (\bar{X}_{.j.} - \bar{X}_{...})^2$
 - 交互作用的效应平方和： $SS_{AB} = c \cdot \sum_{i,j} (\bar{X}_{ij.} - \bar{X}_{i..} - \bar{X}_{.j.} + \bar{X}_{...})^2$
 - 误差平方和： $SS_E = \sum_{i,j,k} (X_{ijk} - \bar{X}_{ij.})^2$
- 快捷计算：令 $T_{ij} = \sum_k X_{ijk}$, $T_{i.} = \sum_j T_{ij}$, $T_{.j} = \sum_i T_{ij}$, $T = \sum_{i,j} T_{ij}$
 - $SS_T = \sum_{i,j,k} X_{ijk}^2 - T^2/abc$, $SS_E = SS_T - SS_A - SS_B - SS_{AB}$
 - $SS_A = \sum_{i,k} T_{i.}^2/ac - T^2/abc$, $SS_B = \sum_{j,k} T_{.j}^2/bc - T^2/abc$
 - $SS_{AB} = \sum_{i,j} T_{ij}^2/c - T^2/abc - S_A - S_B$

回归

Regression



推断、预测

- 变量之间是有关联的
 - 父母的身高和子女的身高 (Galton 1870s-1890s)
 - 人的身高与体重
 - 人的血压与年龄
 - 房价与房子位置、房屋面积
- 推断趋势：一些变量会随着另一些变量的变化如何变化？
- 预测：给定一个或者多个变量，另一个变量可能是？
 - 条件期望、条件概率
 - 是否存在简单的规律？
 - 假设、建模、拟合、检验

回归 (regression)


“回归到平均值” (regression toward the mean)

- 父母的身高和子女的身高 (Galton 1870s-1890s)
 - 父母高, 子女也会高
 - 但是不会太高
 - 父母矮, 子女也会矮
 - 但是不会太矮


- 规律 + 误差 All models are wrong, but some are useful.

- $Y = f(X) + \epsilon$

- $\epsilon \sim N(0, \sigma^2)$



Francis Galton
(1822-1911)



线性回归 (linear regression)

- 最简单最直接的规律

- 模型假设


- 规律符合线性

All models are wrong,
but some are useful.

- $Y_i = a + b \cdot X_i + \epsilon_i$
- $Y_i = a + b \cdot X_i + c \cdot X_i^2 + \epsilon_i$
- $Y = a + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + \epsilon$

- 噪声正态性、齐性、独立性

- $\epsilon_i \sim N(0, \sigma^2)$






参数估计

- 简单线性回归: $Y_i = a + b \cdot X_i + \epsilon_i$ 。模型有多好? 如何选择 a, b ?
 - 最大似然估计 (LME) :

- ▶ $L(a, b, \sigma^2) = \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left(-\frac{1}{2\sigma^2} \sum_i (y_i - a - bx_i)^2 \right)$

- ▶ 最小化 $\sum_i (y_i - a - bx_i)^2$: 最小二乘(least squares)



参数估计

- 最小化 $\sum_i (y_i - a - bx_i)^2$: 最小二乘(least squares)

- 计算:

- 求驻点
$$\begin{cases} 2 \sum_i (y_i - a - bx_i) = 0 \\ 2 \sum_i (y_i - a - bx_i)x_i = 0 \end{cases} \implies \begin{cases} \sum_i y_i = na + b \sum_i x_i \\ \sum_i x_i y_i = a \sum_i x_i + b \sum_i x_i^2 \end{cases}$$

- 解方程组

参数估计

估计方差 σ^2


- 估计 $\hat{y}_i = \hat{a} + \hat{b}x_i$ 会有偏差

- 残差 (residual) : $\hat{y}_i - y_i$; 残差平方和 : $Q = \sum_i (\hat{y}_i - y_i)^2$


- 残差图 : $\hat{y}_i - y_i$ v.s. x_i

- $\frac{Q}{\sigma^2} \sim \chi^2(n - 2)$


- $\mathbb{E} \left[\frac{Q}{n - 2} \right] = \sigma^2$



Predicted vs Actual




Residuals



点预测和预测区间

- 简单线性回归: $Y = a + b \cdot X + \epsilon$, 其中 $\epsilon \sim N(0, \sigma^2)$
- 给定 X , 预测 Y ?
- 误差永远存在, 精确估计不现实
 - 预测关于 X_1, \dots, X_n 的 Y_1, \dots, Y_n 的平均值, n 越大越精确 (大数定理)
 - 预测区间: 给定 X , 预测 Y 可能的范围
- 控制问题: 要求 Y 以 $1 - \alpha$ 概率处于范围 $[y_L, y_U]$, X 应该是多少?



其他话题


- 其实就不是线性关系？
 - 残差图： $\hat{y}_i - y_i$ v.s. x_i
 - 参数假设检验： $b = 0$ ？
 - 拟合优度：判定系数 (coefficient of determination) $R \in [0,1]$
 - $SS_T = \sum_i (y_i - \bar{y})^2 = \sum_i (\hat{y}_i - \bar{y})^2 + \sum_i (y_i - \hat{y}_i)^2 = SS_R + SS_E$
 - $R^2 = SS_R / SS_T$
 - 线性回归的方差分析



方差来源	平方和	自由度	均方(MS)	F比率
回归	SS (regression)	1	SS (regression)	$\frac{MS(\text{regression})}{MS(\text{error})}$
残差	SS (error)	n-2	SS(error) / (n-2)	
总和	SS (total)	n-1		

其他话题

- 区间估计
- 某些模型可转化为线性回归
 - $Y = \alpha \cdot \exp(\beta x) \cdot \epsilon$
 - $\ln Y = \ln \alpha + \beta x + \ln \epsilon$
 - $Y = \alpha \cdot x^\beta \cdot \epsilon$
 - $\ln Y = \ln \alpha + \beta \ln x + \ln \epsilon$
 - $Y = \alpha + \beta \cdot h(x) + \epsilon$
 - $x \mapsto h(x)$
- 非线性回归
 - 对数线性回归、Logistic回归、支持向量回归、岭回归, 等等



其他话题

- 异常值 (离群值, outlier)


- 最小化 $\sum_i (y_i - a - bx_i)^2$

- 少数离群值对均方误差贡献极大, 普通最小二乘对此非常敏感


- 过拟合 (overfitting)

- 足够多的参数可以拟合任何数据, 包括噪点


- $y = a + bx + \epsilon$ v.s. $y = a + bx + cx^2 + dx^3 + \epsilon$



Without overfitting



With overfitting



其他话题

多元线性回归

- $y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i = \mathbf{x}_i^\top \boldsymbol{\beta} + \varepsilon_i$

- $\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_n^\top \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$


- $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$

- $\hat{\boldsymbol{\beta}} = \operatorname{argmin}_{\boldsymbol{\beta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|_2 \approx (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$

- 高维空间最优化问题, 较为复杂 (广告: 详情参见《高级算法》)

信息论初步

Information Theory




信息熵 (Entropy)


- 刻画随机变量“有多随机”

$$H(X) = \sum_x p(x) \log_2 \frac{1}{p(x)}$$

- 度量单位 / 参照物：底数 2。可以替换成任意参照物 (e, 10 等等)
- 为什么这么定义？公理化*
 - 对称性： $H(p_1, p_2, \dots) = H(p_2, p_1, \dots)$
 - 最大熵： $H(p_1, p_2, \dots, p_n) \leq H(1/n, 1/n, \dots, 1/n) = \log n$
 - 连续性
 - 递归性： $H(p_1, p_2, \dots, p_n) = H(p_1 + p_2, \dots, p_n) + (p_1 + p_2) H(p_1 / (p_1 + p_2), p_2 / (p_1 + p_2))$



Claude Shannon
(1916-2001)



Rudolf Clausius
(1822-1888)

信息熵 (Entropy)

简单的性质

$$H(X) = \sum_x p(x) \log_2 \frac{1}{p(x)}$$

- 非负：对于任意随机变量 $H(X) \geq 0$

- 证明： $\forall X, x, 0 \leq \Pr[X = x] \leq 1 \Rightarrow -\log(\Pr[X = x]) \geq 0$

- 可加：如果 X, Y 相互独立，那么联合分布 $H(X, Y) = H(X) + H(Y)$

$$H(X, Y) = - \sum_{x,y} p(x, y) \log_2 p(x, y) = - \sum_{x,y} p(x)p(y) (\log_2 p(x) + \log_2 p(y))$$

$$= - \left(\sum_y p(y) \right) \sum_x p(x) \log_2 p(x) - \left(\sum_x p(x) \right) \sum_y p(y) \log_2 p(y)$$

$$= - \sum_x p(x) \log_2 p(x) - \sum_y p(y) \log_2 p(y) = H(X) + H(Y)$$

二项式系数

$$H(X) = \sum_x p(x) \log_2 \frac{1}{p(x)}$$

- 假设 $nq \in [0, n]$ 是整数, 那么

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{nq} \leq 2^{nH(q)}$$

- (上界) 二项式定理:

$$1 = (q + (1 - q))^n = \sum_{k=0}^n \binom{n}{k} q^k (1 - q)^{n-k} \geq \binom{n}{nq} q^{qn} (1 - q)^{(1-q)n}$$

$$\binom{n}{nq} \leq q^{-qn} (1 - q)^{-(1-q)n} = 2^{-qn \log_2 q} 2^{-(1-q)n \log_2 (1-q)} = 2^{nH(q)}$$

二项式系数

- 假设 $nq \in [0, n]$ 是整数, 那么

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{nq} \leq 2^{nH(q)}$$

- (下界) : 已知 $nq = \operatorname{argmin}_k \binom{n}{k} q^k (1-q)^{n-k}$

二项式定理 $\sum_{k=0}^n \binom{n}{k} q^k (1-q)^{n-k} = (q + (1-q))^n = 1$, 最多 $n+1$ 项:

$$(n+1) \cdot \binom{n}{nq} q^{qn} (1-q)^{(1-q)n} \geq 1 \iff \binom{n}{nq} \geq \frac{q^{qn} (1-q)^{(1-q)n}}{n+1} \geq \frac{2^{nH(q)}}{n+1}$$

二项式系数

- 假设 $nq \in [0, n]$ 是整数, 那么

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{nq} \leq 2^{nH(q)}$$

- (下界) : 目标 $q = \operatorname{argmin}_k \binom{n}{k} q^k (1-q)^{n-k}$

$$\binom{n}{k} q^k (1-q)^{n-k} - \binom{n}{k+1} q^{k+1} (1-q)^{n-k-1} = \binom{n}{k} q^k (1-q)^{n-k} \left(1 - \frac{n-k}{k+1} \frac{q}{1-q} \right)$$

非负, 当 $1 - \frac{n-k}{k+1} \frac{q}{1-q} \geq 0 \iff k \geq qn - 1 + q$

压缩

- 压缩方案: $f: \Omega^n \rightarrow \{0,1\}^*$
- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$, 当 n 足够大:
 - 存在一种压缩使用期望至多 $(1 + \delta)nH(p)$ 个比特压缩长度 n 的抛硬币序列
 - 任意压缩长度 n 的抛硬币序列的压缩方案其期望至少是 $(1 - \delta)nH(p)$ 个比特

压缩

- 压缩方案: $f: \Omega^n \rightarrow \{0,1\}^*$
- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$, 当 n 足够大:
 - 存在一种压缩使用期望至多 $(1 + \delta)nH(p)$ 个比特压缩长度 n 的抛硬币序列
- 令 $\epsilon > 0$ 是足够小的常数满足 $p - \epsilon > 1/2$ 。如果序列中有 $\leq n(p - \epsilon)$ 正面, 编码第一位为1、使用 $n + 1$ 比特编码; 否则第一位为0、对每一种情况使用一种不同的编码 (如, m 种序列 $\lceil \log_2 m \rceil$ 比特)

压缩

- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$ ，当 n 足够大：
 - 存在一种压缩使用期望至多 $(1 + \delta)nH(p)$ 个比特压缩长度 n 的抛硬币序列
- 令 $\epsilon > 0$ 是足够小的常数满足 $p - \epsilon > 1/2$ 。如果序列中有 $\leq n(p - \epsilon)$ 正面，编码第一位为1、使用 $n + 1$ 比特编码
 - (Chernoff) 第一种情况的概率 $\leq \exp(-n\epsilon^2/2p)$ ，全期望 $(n + 1)e^{-n\epsilon^2/2p}$

压缩

$$\binom{n}{nq} \leq 2^{nH(q)}$$

- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$ ，当 n 足够大：
 - 存在一种压缩使用期望至多 $(1 + \delta)nH(p)$ 个比特压缩长度 n 的抛硬币序列
- 令 $\epsilon > 0$ 是足够小的常数满足 $p - \epsilon > 1/2$ 。如果序列中有 $> n(p - \epsilon)$ 正面，第一位为0、对每一种情况使用一种不同的编码

- 第二种情况数目
$$\sum_{i=n(p-\epsilon)}^n \binom{n}{i} \leq \sum_{i=n(p-\epsilon)}^n \binom{n}{n(p-\epsilon)} \leq \frac{n}{2} 2^{nH(p-\epsilon)},$$


使用比特 $1 + \lceil \log_2 \frac{n}{2} 2^{nH(p-\epsilon)} \rceil \leq nH(p - \epsilon) + \log_2 n + 2$

压缩

- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$ ，当 n 足够大：
 - 存在一种压缩使用期望至多 $(1 + \delta)nH(p)$ 个比特压缩长度 n 的抛硬币序列
- 令 $\epsilon > 0$ 是足够小的常数满足 $p - \epsilon > 1/2$ 。如果序列中有 $\leq n(p - \epsilon)$ 正面，编码第一位为1、使用 $n + 1$ 比特编码；否则第一位为0、对每一种情况使用一种不同的编码

$$e^{-n\epsilon^2/2p}(n + 1) + (1 - e^{-n\epsilon^2/2p})(nH(p - \epsilon) + \log_2 n + 2)$$

$o(1)$ $1 - o(1)$ $o(n)$



压缩

- 一枚硬币正面概率 $p > 1/2$ 。对任意小的常数 $\delta > 0$ ，当 n 足够大：
 - 任意压缩长度 n 的抛硬币序列的压缩方案其期望至少是 $(1 - \delta)nH(p)$ 个比特
- 若序列 S_1 比序列 S_2 出现概率更高，那么最优压缩方案满足 $|f(S_1)| \leq |f(S_2)|$
 - 包含 $< n(p + \epsilon)$ 个正面的序列至少使用跟 $n(p + \epsilon)$ 个正面的序列同样多的比特
- 对于任意大小为 s 的序列的集合，一定有一个序列 S 满足 $|f(S)| \geq \log_2 s - 1$
 - 包含 $n(p + \epsilon)$ 个正面的序列需要 $\log_2 \binom{n}{n(p + \epsilon)} - 1 \geq \log_2 \frac{2^{nH((p+\epsilon))}}{n + 1} - 1$
- $(1 - \exp) \cdot (nH(p + \epsilon) - \log_2(n + 1) - 1) \geq (1 - \delta)nH(p)$

压缩

$$H(X) = \sum_x p(x) \log_2 \frac{1}{p(x)}$$

香浓信源编码定理* (source coding theorem)

- 压缩方案：前缀码 $f: \Omega^n \rightarrow \{0,1\}^*$
- 对于任意在 Ω 上的概率分布 D ，对于足够大的 n ：
 - 任意压缩方案都不可能使用期望低于 $nH(D)$ 个比特压缩 $(X_1, \dots, X_n) \sim D$
 - 存在一种压缩方案使用期望 $< nH(D) + 1$ 个比特压缩 $(X_1, \dots, X_n) \sim D$
- 对 $x \in \Omega$ ，使用长度为 $\lceil -\log_2 D(x) \rceil \leq -\log_2 D(x) + 1$ 个比特的编码
- 期望长度 $\leq \sum_x D(x)(-\log_2 D(x) + 1) = H(X) + 1$