

Mínimos cuadrados

Guillermo Ayala Gallego

Mínimos cuadrados

Guillermo Ayala Gallego

2024-03-25

Introducción

- Disponemos de los datos $\{(\mathbf{x}_i, y_i)\}$ con $i=1, \dots, n$ siendo $\mathbf{y} = (y_1, \dots, y_n)^T$, las respuestas observadas; $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})^T$, los predictores correspondientes a la i -ésima observación.
- La matriz de modelo que recoge los valores de los predictores: $\begin{bmatrix} \mathbf{x}_{11} & \dots & \mathbf{x}_{1p} \\ \vdots & \ddots & \vdots \\ \mathbf{x}_{n1} & \dots & \mathbf{x}_{np} \end{bmatrix}$
- Asumimos $\mathbf{\mu} = \mathbf{X}\beta$.
- ¿Cómo estimamos β ?

Planteamiento

Estimadores mínimo cuadráticos

- Una opción clásica son los mínimos cuadrados en donde pretendemos que $\|\mathbf{y} - \hat{\mathbf{\mu}}\|^2$
- Lo que estamos haciendo es sustituir el vector de medias desconocido por los valores observados.
- Consideramos la función $L(\beta) = \sum_{i=1}^n (y_i - \mu_i)^2 = \sum_{i=1}^n \bigg(y_i - \sum_{j=1}^p \beta_j x_{ij} \bigg)^2$.
- Los estimadores mínimo cuadráticos minimizan la función $L(\beta)$. $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$

Predicciones y la matriz \mathbf{H}

- Las medias estimadas las obtenemos con $\hat{\mathbf{\mu}} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$.
- Si denotamos $\mathbf{H} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$, entonces $\hat{\mathbf{\mu}} = \mathbf{H} \mathbf{y}$. $E[\hat{\mathbf{\mu}}] = \mathbf{H} \mathbf{y}$. $\text{var}[\hat{\mathbf{\mu}}] = \sigma^2 (\mathbf{H}^T \mathbf{H})^{-1}$

Residuos

- Tenemos $C(\mathbf{X})^\perp = \text{null}(\mathbf{X}^T)$.
- El espacio $\text{null}(C(\mathbf{X})^\perp)$ básicamente se le puede llamar **espacio del error**.
 - Los residuos son $e = \mathbf{y} - \mathbf{X}\hat{\mathbf{\mu}}$.
- Se tiene $e \in \text{null}(\mathbf{X}^T) = C(\mathbf{X})^\perp$.

Estimando la variación

Modelo

- El modelo lineal que consideramos incorporando el error aleatorio es $\mathbf{Y} = \mathbf{X}\beta + \epsilon$ con $\text{var}(\epsilon) = \sigma^2 \mathbf{I}$.

Estimador insesgado de la varianza

- Se tiene $E[\frac{1}{n-p} \sum_{i=1}^n (Y_i - \hat{\mu}_i)^2] = \sigma^2$.

Estimador insesgado de la varianza \dots

- En el caso en que la matriz modelo no tuviera rango completo ($\text{rank}(\mathbf{X}) = r < p$) entonces la misma prueba nos valdría sustituyendo (p) por (r) .
- El estimador seguiría siendo insesgado.
- El estimador (S^2) recibe el nombre de **cuadrado medio del error** o **cuadrado medio residual**.
- Su raíz cuadrada, (S) es el **error estándar residual**.
- (S^2) es un estimador insesgado de (σ^2) mientras que (S) no es un estimador insesgado de (σ) .

Coeficiente de determinación

- Se define como
$$\begin{aligned} R^2 &= \frac{SS(\text{Regression})}{SS(\text{Total})} = \frac{SS(\text{Total}) - SS(\text{Residual})}{SS(\text{Total})} \\ &= \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \end{aligned}$$
- El coeficiente de correlación muestral se define como
$$\text{corr}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \sum_{i=1}^n (y_i - \bar{y})^2}.$$
- Se verifica $\text{corr}(\mathbf{y}, \hat{\mathbf{y}}) = +\sqrt{R^2}$.
- La raíz cuadrada positiva de (R^2) recibe el nombre de **correlación múltiple**.
- (R^2) ajustada es $R^2_{\text{adjusted}} = 1 - \frac{SS(\text{Residual})/(n-p)}{SS(\text{Total})/(n-1)} = 1 - \frac{n-1}{n-p} (1 - R^2)$.

Residuo estandarizado

- Se define como $r_i = \frac{y_i - \hat{y}_i}{\sqrt{\sum_{i=1}^n e_i^2 / (n-p)}}$.
- El **residuo studentizado** se define como el residuo estandarizado lo que ocurre es que el ajuste se realiza sin considerar el propio punto.

tamidata2::gse25171

Con time y Pi

- Analizamos los datos correspondientes a la sonda 261892_at.
- Consideramos las variables fenotípicas time y Pi.

```
1 pacman::p_load(BioBase)
2 data(gse25171, package="tamidata2")
3 head(pData(gse25171), n=2)

      time time2      Pi replication
GSM618324.CEL.gz    0 Short Treatment      1
GSM618325.CEL.gz    0 Short Control       2

1 sel0 = which("261892_at"==fData(gse25171)[, "PROBEID"])
2 df0 = data.frame(pData(gse25171)[, c("time", "Pi")],
```

```

3   expression=exprs(gse25171)[sel0,])

  • Ajustamos un modelo con dos variables predictoras.

1 fit4 = lm(expression~ time + Pi,data=df0)
  • La matriz modelo es

1 head(model.matrix(fit4),n=5)
      (Intercept) time PiTreatment
GSM618324.CEL.gz      1    0        1
GSM618325.CEL.gz      1    0        0
GSM618326.CEL.gz      1    1        1
GSM618327.CEL.gz      1    1        0
GSM618328.CEL.gz      1    6        1

  • Los coeficientes los tenemos con

1 coef(fit4)
      (Intercept)      time PiTreatment
8.6293898 -0.1330703 -1.3219071

  • Los residuos los tenemos con

1 resid(fit4)
      GSM618324.CEL.gz GSM618325.CEL.gz GSM618326.CEL.gz GSM618327.CEL.gz
      1.01552765     0.21676116    -0.32266386   -0.07784405
      GSM618328.CEL.gz GSM618329.CEL.gz GSM618330.CEL.gz GSM618331.CEL.gz
      -0.59106601     0.31824015    0.22638066   -0.30489608
      GSM618332.CEL.gz GSM618333.CEL.gz GSM618334.CEL.gz GSM618335.CEL.gz
      0.49588789    -0.15067778   -0.63263328    0.15231308
      GSM618336.CEL.gz GSM618337.CEL.gz GSM618338.CEL.gz GSM618339.CEL.gz
      -0.93990720     0.45816343    0.21916840   -0.92275255
      GSM618340.CEL.gz GSM618341.CEL.gz GSM618342.CEL.gz GSM618343.CEL.gz
      0.24175878     0.15101414   -0.46350659    0.52297219
      GSM618344.CEL.gz GSM618345.CEL.gz GSM618346.CEL.gz GSM618347.CEL.gz
      -0.39355515    -0.42938559    1.14460870    0.06609189

  • El error estándar residual lo tenemos con

1 summary(fit4)$sigma
[1] 0.5644856

```

Con time2 y Pi

- Analizamos los datos correspondientes a la sonda 261892_at.
- Consideramos las variables fenotípicas time2 y Pi.

```

1 pacman::p_load(Bioconductor)
2 data(gse25171, package="tamidata2")
3 head(pData(gse25171), n=2)

      time time2      Pi replication
GSM618324.CEL.gz    0 Short Treatment      1
GSM618325.CEL.gz    0 Short Control       2

1 sel0 = which("261892_at" == fData(gse25171)[, "PROBEID"])
2 df0 = data.frame(pData(gse25171)[, c("time2", "Pi")],
                  expression=exprs(gse25171)[sel0,])

```

- Ajustamos un modelo con dos variables predictoras. Ambas son categóricas y consideramos un modelo de análisis de la varianza con dos vías.

```

1 fit5 = aov(expression ~ time2 + Pi, data=df0)

• La matriz modelo es

1 head(model.matrix(fit5), n=5)

  (Intercept) time2Medium PiTreatment
GSM618324.CEL.gz      1          0      1
GSM618325.CEL.gz      1          0      0
GSM618326.CEL.gz      1          0      1
GSM618327.CEL.gz      1          0      0
GSM618328.CEL.gz      1          1      1

```

- La tabla de análisis de la varianza la tenemos con

```

1 summary(aov(fit5))

  Df Sum Sq Mean Sq F value    Pr(>F)
time2      1 26.99  26.992   29.36 2.24e-05 ***
Pi         1 10.48  10.485   11.41  0.00285 **
Residuals 21 19.30   0.919
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

- ¿Y un modelo con interacción?

```

1 fit6 = aov(expression ~ time2 * Pi, data=df0)

• Vemos la tabla anova.

1 summary(fit6)

  Df Sum Sq Mean Sq F value    Pr(>F)
time2      1 26.992  26.992   28.02 3.51e-05 ***
Pi         1 10.485  10.485   10.88  0.00358 **
time2:Pi   1  0.038   0.038    0.04  0.84370
Residuals 20 19.264   0.963
---

```

```
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

- No parece que tengamos interacción.

Muchos modelos

Un modelo por fila con GSEAlm

- Hemos elegido trabajar con una sonda elegida de un modo arbitrario.
- Tenemos interés en todas las sondas.
- Hemos de ajustar un modelo lineal para cada una de estas sondas.
- Los predictores serán variables fenotípicas compartidas por todas las sondas.
- Los distintos modelos comparten los predictores y difieren en la variable respuesta.

```
1 pacman::p_load(GSEAlm)
2 data(gse25171, package="tamidat2")
3 fits1 = GSEAlm::lmPerGene(gse25171, ~ time + Pi)
```

- La matriz de modelo común a todos los ajustes la tenemos con

```
1 head(fits1$x)
```

	(Intercept)	time	PiTreatment
GSM618324.CEL.gz	1	0	1
GSM618325.CEL.gz	1	0	0
GSM618326.CEL.gz	1	1	1
GSM618327.CEL.gz	1	1	0
GSM618328.CEL.gz	1	6	1
GSM618329.CEL.gz	1	6	0

- Los coeficientes de cada ajuste con

```
1 fits1$coefficients
```

- Para la primera sonda tenemos los coeficientes

```
1 fits1$coefficients[,1]
```

	(Intercept)	time	PiTreatment
	5.080830082	0.003844458	0.010492799

- Las varianzas del error estimadas son

```
1 fits1$sigmaSqr
```

Y los estadísticos correspondientes a los tests de coeficientes nulos con

```
1 fits1$tstat
```

Un modelo por fila con limma

```
1 pacman::p_load(limma)
  • Ajustamos los modelos.
1 design = model.matrix(~ pData(gse25171)[, "time"] + pData(gse25171)[, "Pi"])
2 fits2 = limma::lmFit(gse25171,design)
  • Los coeficientes los tenemos con
1 head(fits2$coefficients,n=2)
  (Intercept) pData(gse25171)[, "time"]
244901_at      5.080830          0.003844458
244902_at      4.843889          -0.005471131
  pData(gse25171)[, "Pi"]Treatment
244901_at           0.0104927991
244902_at           -0.0009233809
  • Los coeficientes del ajuste para la primera sonda son
1 fits2$coefficients[1,]
  (Intercept)      pData(gse25171)[, "time"]
5.080830082          0.003844458
pData(gse25171)[, "Pi"]Treatment
0.010492799
```