

## Modelo Lineal: Diagnóstico

**Verificación de Supuestos y Diagnóstico** Supongamos que tenemos una muestra  $(y_i, \mathbf{x}_i)$ ,  $i = 1, \dots, n$  que cumple:

$$y_i = \mathbf{x}_i' \boldsymbol{\beta} + \epsilon_i$$

donde  $\epsilon_i = N(0, \sigma^2)$  son independientes y estimamos por el método de mínimos cuadrados a  $\boldsymbol{\beta}$  y realizamos todas las inferencias que necesitamos.

**¿Cómo verificamos todos los supuestos que hemos realizado?**

Los 4 supuestos que revisaremos son:

1. Linealidad:  $E(Y) = \mathbf{X}\boldsymbol{\beta}$
2. Homoscedasticidad:  $Var(\epsilon_i) = \sigma^2 = cte.$
3. Normalidad:  $\epsilon_i$  tienen distribución Normal
4. Independencia de los errores:  $\epsilon_i$  independiente de  $\epsilon_j$  si  $i \neq j$ .

Comencemos por considerar los residuos:

$$e_i = y_i - \hat{y}_i \quad i = 1, \dots, n$$

Como sabemos

$$\mathbf{e} = (\mathbf{I} - \mathbf{P})\mathbf{Y}$$

por lo tanto

$$E(\mathbf{e}) = \mathbf{0} \quad \Sigma_{\mathbf{e}} = \sigma^2(\mathbf{I} - \mathbf{P})$$

Por lo tanto,  $V(e_i) = \sigma^2(1 - p_{ii})$ , con lo cual los residuos son heteroscedásticos.

Si además, los errores son normales, como hemos supuesto antes

$$\mathbf{e}_i \sim N(0, \sigma^2(1 - p_{ii}))$$

Observemos además, que los residuos no son independientes, en tanto:

$$\text{Cov}(e_i, e_j) = -\sigma^2 p_{ij}$$

Definimos otros residuos relacionados:

$$r_i = \frac{y_i - \hat{y}_i}{s\sqrt{(1 - p_{ii})}} \quad \text{residuo standarizado}$$

$$r_i^* = \frac{y_i - \hat{y}_i}{s_{(i)}\sqrt{(1 - p_{ii})}} \quad \text{residuo studentizado}$$

donde  $s_{(i)}$  es el desvío standard muestral computado partir de una regresión ajustada sin la observación  $i$ .

Sea  $\mathbf{X}_{(i)}$  la matriz  $\mathbf{X}$  sin la  $i$ -ésima fila:  $\mathbf{x}_i$ . Probarán en la práctica que son ciertas las siguientes igualdades:

$$\begin{aligned}\mathbf{X}'_{(i)}\mathbf{X}_{(i)} &= \mathbf{X}'\mathbf{X} - \mathbf{x}_i\mathbf{x}'_i \\ (\mathbf{X}'_{(i)}\mathbf{X}_{(i)})^{-1} &= (\mathbf{X}'\mathbf{X})^{-1} + \frac{(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i\mathbf{x}'_i(\mathbf{X}'\mathbf{X})^{-1}}{1 - p_{ii}}\end{aligned}$$

con lo cual

$$\begin{aligned}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}_{(i)} &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_i\frac{e_i}{1 - p_{ii}} \\ s_{(i)}^2 &= \frac{(n - p)s^2 - e_i^2(1 - p_{ii})}{n - p - 1}\end{aligned}$$

## Distribución de los Residuos

A fin de estudiar la distribución de estos residuos podríamos graficar:

- Esquemas de Tallo y Hoja
- Histogramas

- Boxplots

De esta forma podríamos evaluar:

- simetría
- valores extremos
- valores centrales
- outliers
- posibles agrupamientos
- normalidad

```
summary(salida)
```

```
Call:
```

```
lm(formula = BIO ~ K + PH)
```

```
Residuals:
```

```
    Min      1Q  Median      3Q     Max
```

-679.25 -253.50 -95.44 259.45 1135.80

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-506.7131	279.8016	-1.811	0.0773	.
K	-0.4871	0.2031	-2.398	0.0210	*
PH	411.9779	48.4954	8.495	1.15e-10	***

Residual standard error: 401.1 on 42 degrees of freedom  
Multiple R-squared: 0.6476, Adjusted R-squared: 0.6308  
F-statistic: 38.59 on 2 and 42 DF, p-value: 3.074e-10

names(salida)

[1]	"coefficients"	"residuals"	"effects"	"rank"	"fitted.values"	"assign"
[8]	"df.residual"	"xlevels"	"call"	"terms"	"model"	

names(lm.influence(salida))

[1]	"hat"	"coefficients"	"sigma"	"wt.res"
-----	-------	----------------	---------	----------

```
stem(salida$res/( 401.1*sqrt(1-lm.influence(salida)$hat)))
```

The decimal point is at the |

```
-1 | 9
-1 | 332
-0 | 988877776665555
-0 | 332211111
 0 | 022
 0 | 677778
 1 | 04
 1 | 69
 2 | 01
 2 | 9
```

```
boxplot(salida$res/( 401.1*sqrt(1-lm.influence(salida)$hat)))
```

```
qqnorm(salida$res/( 401.1*sqrt(1-lm.influence(salida)$hat)))
```

## Chequeando la Normalidad

El QQ-plot es un gráfico de percentiles muestrales vs. percentiles teóricos (bajo una cierta distribución asumida  $F$ ).

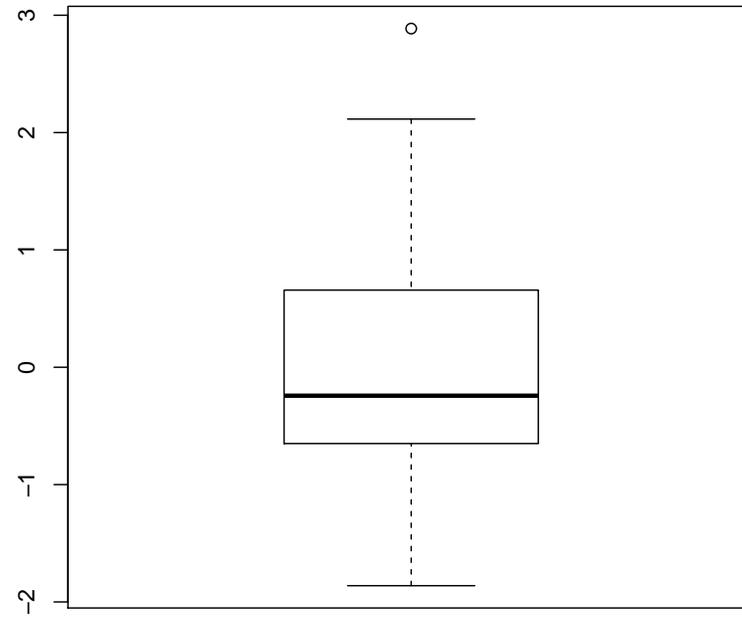


Figura 1: Boxplot de  $r_i$ : Datos de Biomasa

Si la muestra proviniese de una población con distribución  $F$  los percentiles muestrales vs. los teóricos caerían aproximadamente sobre una recta a  $45^\circ$ .

Para esto ordenamos los residuos standarizados

$$r_{(1)} \leq r_{(2)} \leq \dots \leq r_{(n)}$$

y graficamos los percentiles muestrales  $\{1/(n+1), 2/(n+1), \dots, n/(n+1)\}$  contra los percentiles teóricos de una  $N(0, 1)$   $\{\phi^{-1}(1/(n+1)), \phi^{-1}(2/(n+1)), \dots, \phi^{-1}(n/(n+1))\}$ .

Si el gráfico se desviase de la recta, estaríamos encontrando evidencia contra la normalidad.

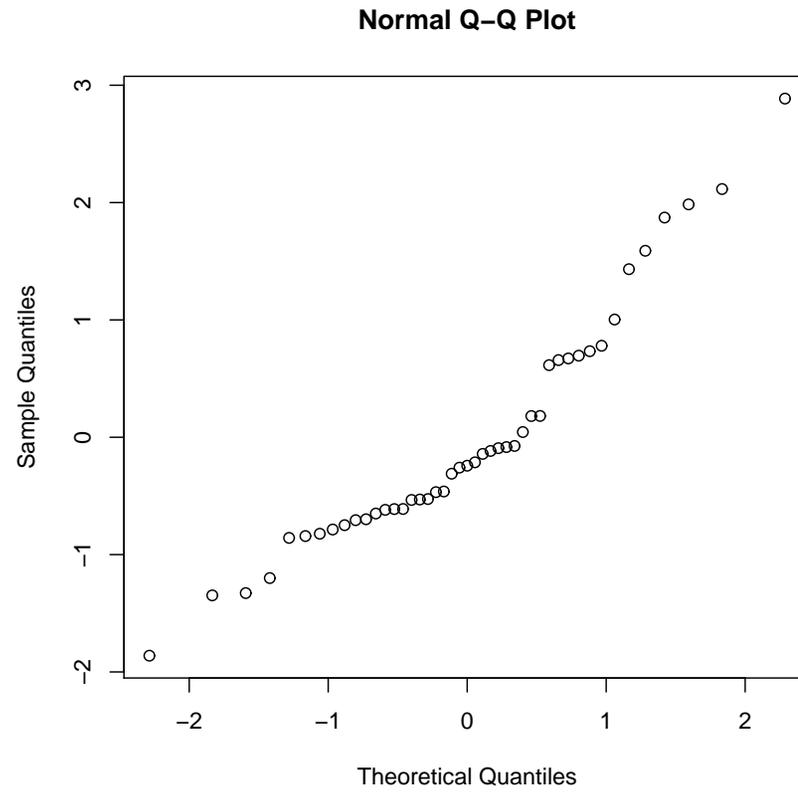


Figura 2: QQ-plot de  $r_j$ : Datos de Biomasa

## Linealidad

$\hat{y}_i$  vs.  $e_i$

Uno de los gráficos que se realiza después de realizar el ajuste es el de  $\hat{y}_i$  vs.  $e_i$

**¿Qué esperamos observar?** Consideremos el modelo  $y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_{p-1} x_{i(p-1)}$

Si quisiéramos hacer una regresión entre  $e_i$  vs.  $\hat{y}_i$  el estimador de la pendiente tendría como numerador:

$$\sum_{i=1}^n (e_i - \bar{e})(\hat{y}_i - \bar{y}) = \sum_{i=1}^n e_i \hat{y}_i = \mathbf{Y}(\mathbf{I} - \mathbf{P})\mathbf{P}\mathbf{Y} = 0$$

En cambio si la regresión la hiciésemos entre  $e_i$  vs.  $y_i$  el estimador de la pendiente tendría como numerador:

$$\sum_{i=1}^n (e_i - \bar{e})(y_i - \bar{y}) = \sum_{i=1}^n e_i y_i = \mathbf{Y}'(\mathbf{I} - \mathbf{P})\mathbf{Y} = \mathbf{Y}'(\mathbf{I} - \mathbf{P})(\mathbf{I} - \mathbf{P})\mathbf{Y} = \mathbf{e}'\mathbf{e} = \|\mathbf{e}\|^2$$

es decir, la suma de cuadrados de los residuos.

Más aún, el estimador del coeficiente correspondiente a la pendiente en este caso sería:

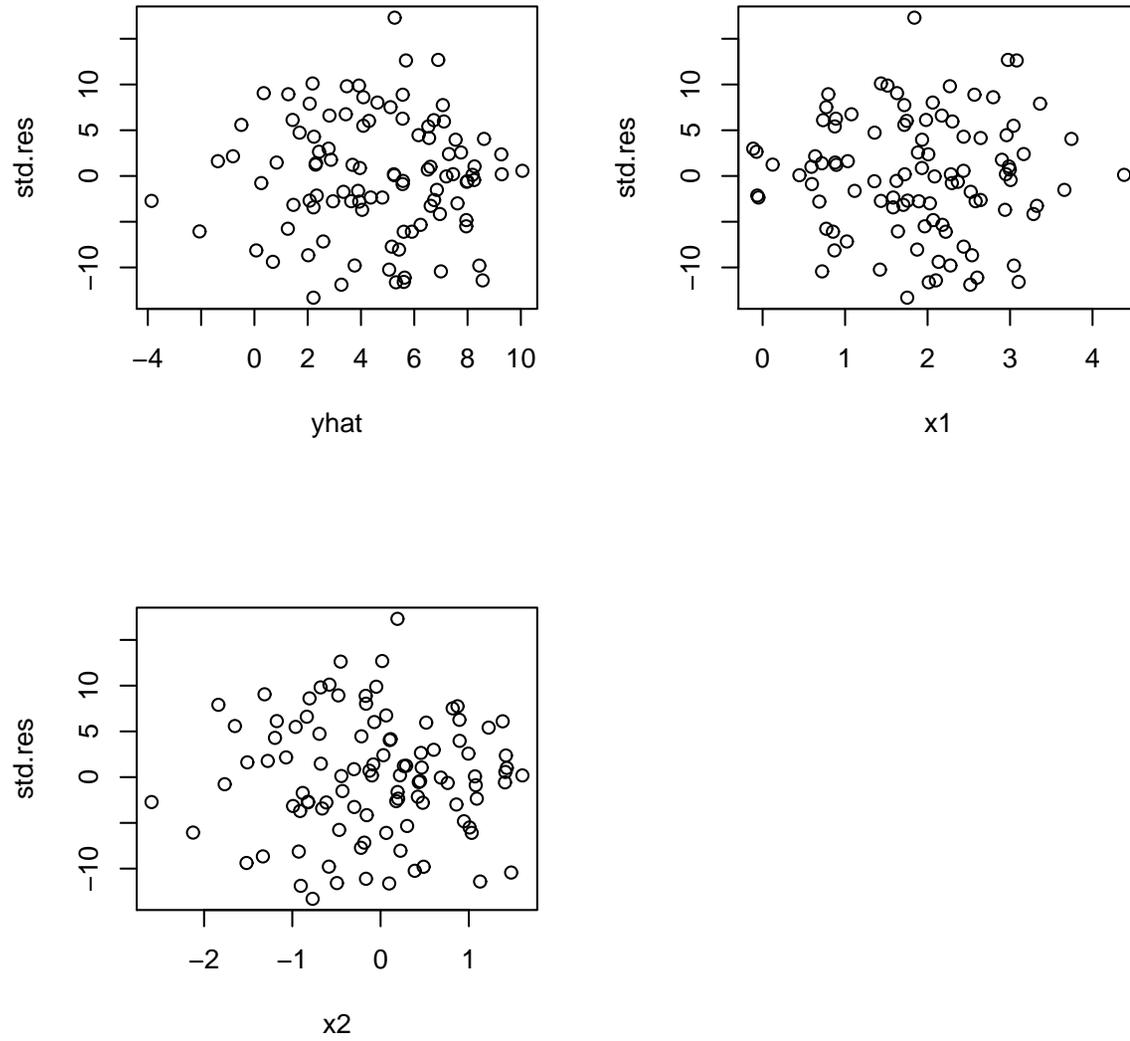


Figura 3: Linealidad: OK!!

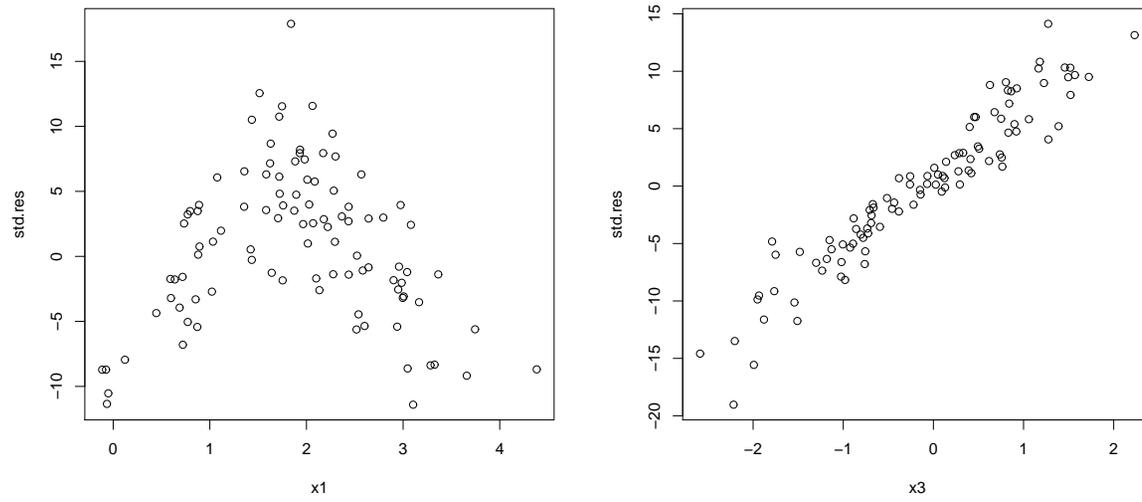
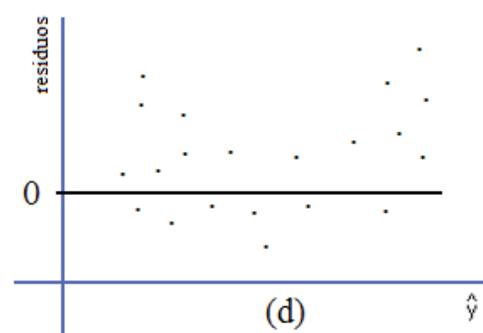
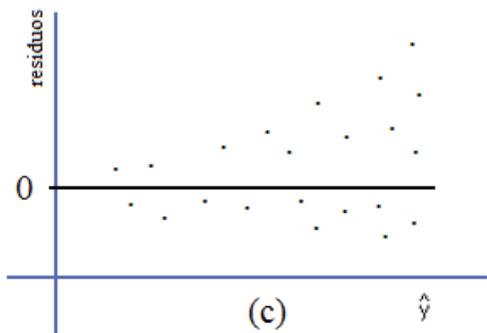
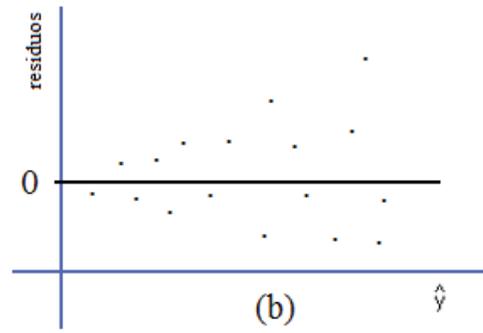
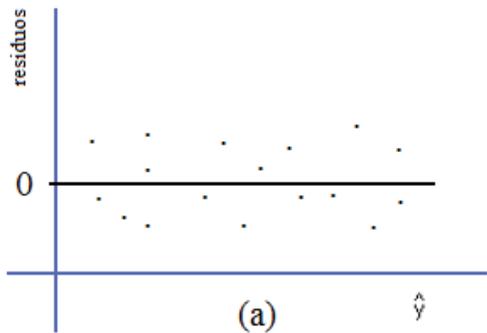


Figura 4: Linealidad: MAL!!



(a)  
Representa la situación esperable si el modelo se cumple: una nube de residuos alrededor del 0 sin estructura.

(b) y (c)  
Muestran gráficos en los que el supuesto de igualdad de varianzas no se cumple.

(d) El supuesto de linealidad no se satisface.

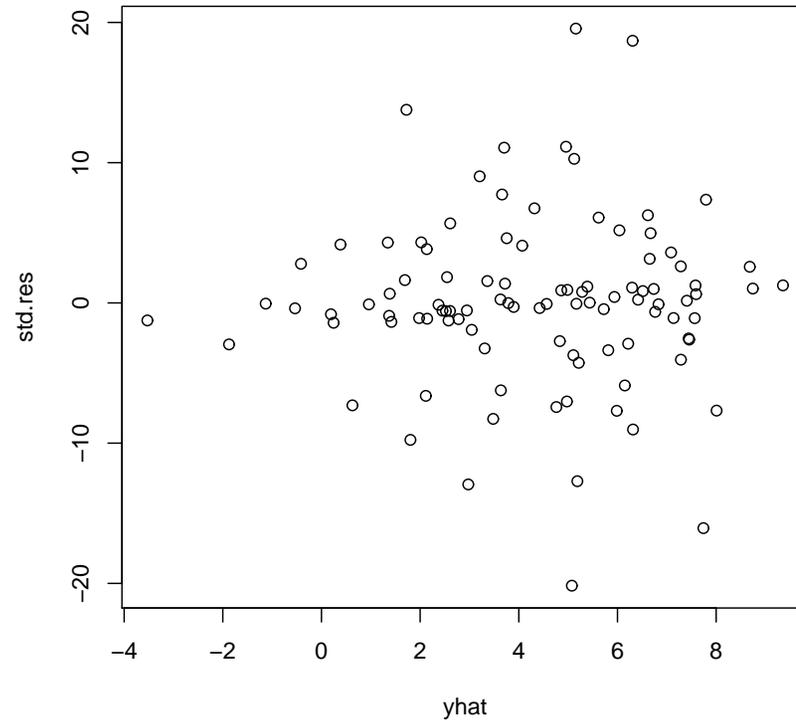


Figura 6: Boxplot de  $r_i$ : Heteroscedaticidad

$$\frac{\mathbf{e}'\mathbf{e}}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - R^2$$

Es decir que esta pendiente sería 0 sólo en el caso de ajuste perfecto.

El caso (d) correspondería a un modelo inadecuado. Por ejemplo, supongamos que ajustamos  $y_i = \beta_0 + \beta_1 x_{i1} + \epsilon_i$ , pero en realidad es:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i$$

Luego:

$$\begin{aligned} E(e_i) &= E(y_i - \hat{y}_i) \\ &= E(y_i - \hat{\beta}_0 + \hat{\beta}_1 x_{i1}) \\ &= h + g x_{i1} + k x_{i2} \end{aligned}$$

o sea tanto  $e_i$  como  $y_i$  varían con  $x_{i1}$ .

**$e_i$  vs. cada variable regresora**

Tengamos en cuenta que por las ecuaciones normales:

$$\sum_{i=1}^n (e_i - \bar{e})(x_{ij} - \bar{x}_{.j}) = \sum_{i=1}^n e_i (x_{ij} - \bar{x}_{.j}) = \sum_{i=1}^n e_i x_{ij} = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} + \dots - \hat{\beta}_{p-1} x_{i(p-1)}) x_{ij} = 0$$

De manera que, si el modelo elegido fuera correcto no debería aparecer ninguna estructura en el gráfico de  $e_i$  vs.  $x_{ij}$ . Por lo tanto, los gráficos anteriores también nos sirven de guía en este caso.

Por ejemplo, si en el razonamiento anterior reemplazásemos  $x_{i2}$  por  $x_{i1}^2$  tendríamos:

$$E(e_i) = h + gx_{i1} + kx_{i1}^2$$

el gráfico quedaría cercano a una parábola.

### **$e_i$ vs. tiempo**

En principio cualquier factor podría influir en  $Y$  y debería incluirse en la regresión como variable explicativa. Si un factor ha sido omitido, podría graficarse  $e_i$  vs. factor y ver si hay alguna tendencia o patrón particular.

A veces con los datos se registra el tiempo o el orden en que han sido tomadas las mediciones. Puede ser de interés estudiar si los residuos tienen alguna dependencia en el tiempo.

