

ESTADISTICA Y ANALISIS DE DATOS

Regresión estadística

Autor: Josemari Sarasola

sigmalitika.hirusta.io

0.4. Ejercicios sobre regresión

1. Se han recogido datos sobre horas de estudio semanales y calificaciones de matemáticas en un grupo de alumnos:

Alumno	A	B	C	D	E
Horas de estudio	2	3	4	6	8
Calificación	3.2	4.6	6	5.8	8.4

- a) Estime e interprete los parámetros de la recta de regresión que relaciona la dos variables.
 b) Calcule las predicciones y los errores.
 c) Dibuje la nube de puntos y la recta de regresión, así como un término de error.
2. A lo largo de varios días de agosto se han recogido datos sobre temperatura máxima y ventas de helados (en euros) en un establecimiento. He aquí los datos:

Día	1	2	3	4	5	6	7	8
Ventas	124	145	202	196	154	176	188	167
Temperatura	25	29	42	39	28	37	38	33

- a) Especifique la recta de regresión minimocuadrática.
 b) Para mañana se ha pronosticado una temperatura máxima de 35 grados. En base a ello, haga una predicción para las ventas de helados. Sería adecuado hacer una predicción del mismo modo para una temperatura de 10 grados? Analice la fiabilidad de las predicciones.
 c) Dibuje e interprete el diagrama de errores.
3. En una factoría se ha realizado un experimento controlando las horas de mantenimiento y observando su efecto en la producción diaria. Estos son los datos compilados:

Día	1	2	3	4	5	6
Horas de mantenimiento	2	3	4.5	6	7	8
Producción	4	6	9	11	11.5	11.8

- a) Especifique la recta de regresión minimocuadrática y su coeficiente de determinación. Es la recta ajustada a los datos?
 b) Dibuje la nube de puntos y establezca la línea que pueda ajustarse mejor a dicha nube.
 c) Ajuste la curva $\hat{w} = k - \frac{m}{v}$ a los datos y establezca la producción máxima para ella. Calcule el coeficiente de determinación a partir de la varianza de las predicciones.
 d) Ajuste la curva $\hat{w} = kv^m$ a los datos y analice si es más ajustada que la curva anterior. Nota: calcule R^2 a través de la varianza residual.
4. A lo largo de varios experimentos se han recogido datos sobre la probabilidad de parada de un dispositivo a diferentes temperaturas:

Temperatura	38	46	54	68	80
Probabilidad de parada	0.12	0.24	0.38	0.58	0.94

- a) Ajuste la curva $\hat{w} = ke^{mv}$ a los datos.
 b) Para que la probabilidad de parada sea inferior a 0.5, cuál debe ser la temperatura?
 c) Para qué temperatura se considera segura la parada?
 d) Analice la bondad de ajuste a través de la varianza residual.
5. Se han inyectado diferentes dosis de un fármaco a ratones y para cada dosis se ha calculado el porcentaje de ratones que han experimentado una mejoría::

Dosis (mg)	4	6	8	12
Porcentaje de mejora	22%	43%	69%	82%

- a) Haga una predicción del porcentaje de mejora para una dosis de 10 mg, a través del modelo logit.
 b) Calcule la dosis necesaria para un porcentaje de mejora del 99%.
 c) Analice la bondad de ajuste a través de la varianza de las predicciones.

6. En un examen de conducir colectivo, se compiló el número de horas de entrenamiento y si se aprobó el examen. He aquí los datos:

Horas	Ha aprobado?
4	no-si-no-no-no-no-no-no-no
5	no-si-no-no-no-si-si-no-no-no
8	no-si-si-no-si-no-si-si-no-no
10	si-si-si-si-si-si-no-no-no-no
14	no-si-si-si-si-si-si-si-si-si

- a) A través del modelo logit, haga una predicción sobre le número de horas necesario para aprobar con el 99 % de probabilidad.
- b) Idem, con una probabilidad del 99.9 % . Interprete ambos resultados en relación a las propiedades de la curva logística.
7. Se han recogido datos sobre el porcentaje de plantas que pueden considerarse comestibles con diferentes dosis de un producto fitosanitario:

Dosis (mg)	4	6	8	12
Porcentaje de comestibles	90 %	67 %	54 %	12 %

- a) Si se persigue un porcentaje de comestibles del 80 %, calcule para ello la dosis máxima del producto, con el modelo logit.
- b) Calcule el coeficiente de determinación, a través de la varianza residual.

Plantillas de resolución

Ejercicio 1

x_i	y_i	$x_i y_i$	x_i^2	$\hat{y} =$ + x_i	$e_i = y_i - \hat{y}_i$
2	3.2				
3	4.6				
4	6				
6	5.8				
8	8.4				

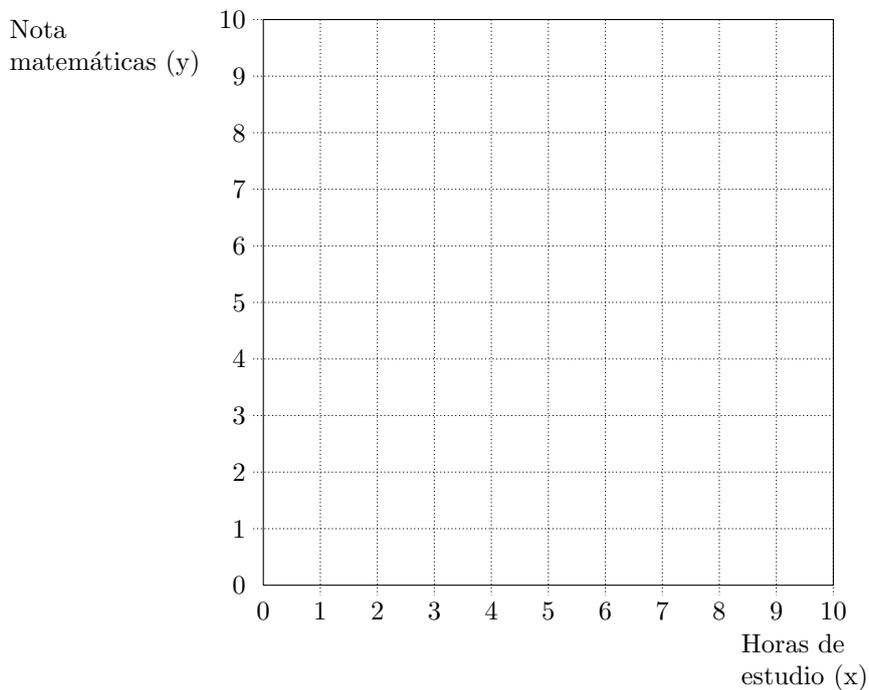
$\bar{x} =$; $\bar{y} =$

$$s_{xy} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{n-1} =$$

$$s_x^2 = \frac{\sum x_i^2 - n \bar{x}^2}{n-1} =$$

$$\left. \begin{matrix} s_{xy} = \dots \\ s_x^2 = \dots \end{matrix} \right\} b = \frac{s_{xy}}{s_x^2} =$$

$a = \bar{y} - b\bar{x} =$



Ejercicio 2

(a)

x_i	y_i	$x_i y_i$	x_i^2

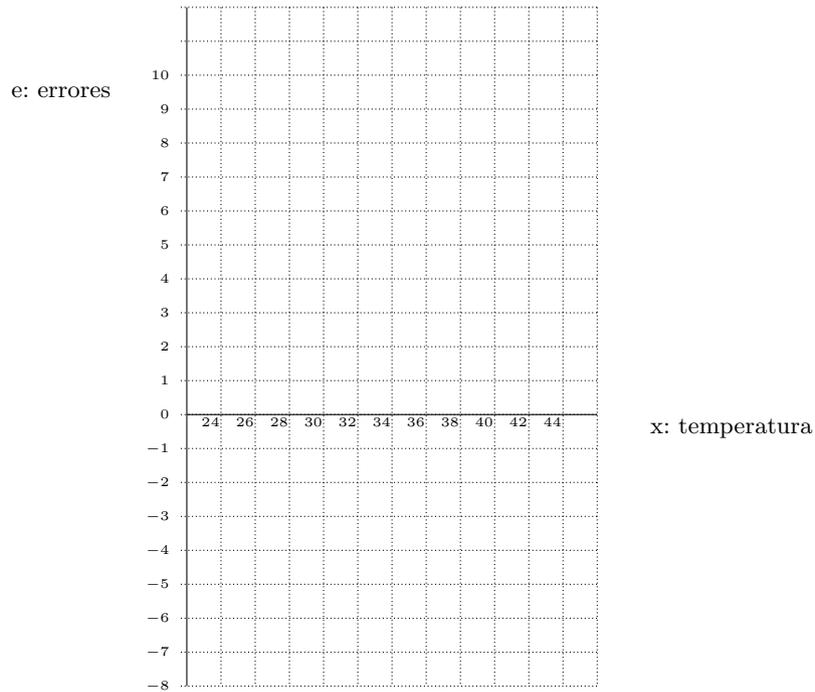
- $\bar{x} =$
- $\bar{y} =$
- $s_{xy} =$
- $s_x^2 =$
- $b = \frac{s_{xy}}{s_x^2} =$
- $a = \bar{y} - b\bar{x} =$

(b)

$\hat{y} =$	$+$	x_i	$e_i = y_i - \hat{y}_i$	y^2	\hat{y}^2	e^2

- $s_y^2 = \frac{\sum y^2}{n} - \bar{y}^2 =$
- $s_{\hat{y}}^2 = \frac{\sum \hat{y}^2}{n} - \bar{\hat{y}}^2 =$
- $s_e^2 = \frac{\sum e^2}{n} - \bar{e}^2 = \frac{\sum e^2}{n} =$
- $R^2 = \frac{s_{\hat{y}}^2}{s_y^2} =$
- $R^2 = 1 - \frac{s_e^2}{s_y^2} =$

(c)



Ejercicio (3)

(a)

x_i	y_i	$x_i y_i$	x_i^2

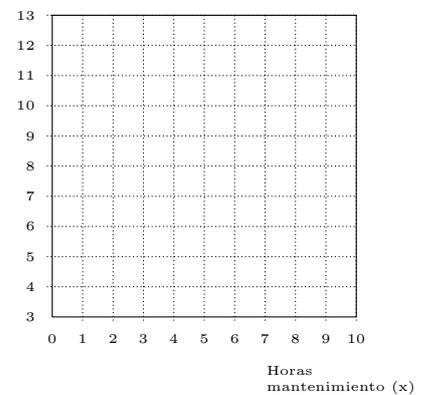
- $\bar{x} =$
- $\bar{y} =$
- $s_{xy} =$
- $s_x^2 =$
- $b = \frac{s_{xy}}{s_x^2} =$
- $a = \bar{y} - b\bar{x} =$

(b)

$\hat{y} =$	$+ x_i$	y^2	\hat{y}^2

- $s_y^2 = \frac{\sum y^2}{n} - \bar{y}^2 =$
- $s_{\hat{y}}^2 = \frac{\sum \hat{y}^2}{n} - \bar{\hat{y}}^2 =$
- $R^2 = \frac{s_{\hat{y}}^2}{s_y^2} =$

Producción (y)



Ejercicio (4)

v_i	w_i	$x_i =$	$y_i =$	$x_i y_i$	x_i^2	$\hat{y}_i =$	$e_i = y_i - \hat{y}_i$	y_i^2	e_i^2

- $\bar{x} =$
- $\bar{y} =$
- $s_{xy} =$
- $s_x^2 =$
- $b = \frac{s_{xy}}{s_x^2} =$
- $a = \bar{y} - b\bar{x} =$
- $s_y^2 = \frac{\sum y^2}{n} - \bar{y}^2 =$
- $s_e^2 = \frac{\sum e^2}{n} =$
- $R^2 = 1 - \frac{s_e^2}{s_y^2} =$

Ejercicio (5)

x_i	p_i	$y_i = \ln \frac{p_i}{1-p_i}$	$x_i y_i$	x_i^2	$\hat{y}_i =$	\hat{y}_i^2	y_i^2

- $\bar{x} =$

- $\bar{y} =$

- $s_{xy} =$

- $s_x^2 =$

- $b = \frac{s_{xy}}{s_x^2} =$

- $a = \bar{y} - b\bar{x} =$

- $s_y^2 = \frac{\sum y^2}{n} - \bar{y}^2 =$

- $s_{\hat{y}}^2 = \frac{\sum \hat{y}^2}{n} - \bar{\hat{y}}^2 =$

- $R^2 = \frac{s_{\hat{y}}^2}{s_y^2} =$

Ejercicio (6)

x_i	n_i zenbatetik	p_i	$y_i = \ln \frac{p_i}{1 - p_i}$	$x_i y_i$	x_i^2

■ $\bar{x} =$

■ $\bar{y} =$

■ $s_{xy} =$

■ $s_x^2 =$

■ $b = \frac{s_{xy}}{s_x^2} =$

■ $a = \bar{y} - b\bar{x} =$

Ejercicio (7)

Como puede observarse al examinar los datos, en este caso la probabilidad disminuye a medida que se aumenta la dosis, de modo que no podemos aplicar el modelo logit tal como lo hemos planteado en un principio. Sin embargo, la solución es inmediata: no tenemos más que sustituir a la probabilidad de ser comestible por la probabilidad complementaria de ser incomedible como variable dependiente.

x_i	p_{1i}	p_{2i}	$y_i = \ln \frac{p_{2i}}{1 - p_{2i}}$	$x_i y_i$	x_i^2	$\hat{y}_i = -4,02 + 0,50x$	$e_i = y_i - \hat{y}_i$	y_i^2	e_i^2
4	0.90	0.10	-2.20	-8.79	16	-2.02	-0.18	4.83	0.031
6	0.67	0.33	-0.71	-4.25	36	-1.02	0.31	0.50	0.097
8	0.54	0.46	-0.16	-1.28	64	-0.02	-0,14	0.02	0.019
12	0.12	0.88	1.99	23.91	144	1.98	0.01	3.97	0.000
30			-1.07	9.59	260	-1.07	0	9.32	0.1484

- $\bar{x} = \frac{30}{4} = 7,5; \bar{y} = \frac{-1,07}{4} = -0,27$

- $s_{xy} = \frac{9,59}{4} - 7,5 \times -0,27 = 4,42$

- $s_x^2 = \frac{260}{4} - 7,5^2 = 8,75$

- $b = \frac{s_{xy}}{s_x^2} = \frac{4,42}{8,75} = 0,50; a = \bar{y} - b\bar{x} = -0,27 - 0,50 \times 7,5 = -4,02 \rightarrow \ln \left(\frac{p}{1-p} \right) = -4,02 + 0,50x$

- $p_1 = 0,8 \rightarrow p_2 = 0,2 \rightarrow \ln \left(\frac{0,2}{1-0,2} \right) = -4,02 + 0,50 * x \rightarrow -1,38 = -4,02 + 0,50 * x \rightarrow x = 5,28$

- $s_y^2 = \frac{\sum y^2}{n} - \bar{y}^2 = \frac{9,32}{4} - (-0,27)^2 = 2,25$

- $s_e^2 = \frac{\sum e^2}{n} = \frac{0,1484}{4} = 0,0371$

- $R^2 = 1 - \frac{s_e^2}{s_y^2} = 1 - \frac{0,371}{2,25} = 0,986 \rightarrow$ muy buen ajuste