

# **Coeficientes de correlación y de determinación**

# Regresión lineal

Sirve para modelar la relación entre X y Y mediante una recta:

$$y = mx + b$$

Donde:

- $m$  = pendiente
- $b$  = intercepto
- $X$  = variable independiente
- $Y$  = valor estimado de la variable dependiente

La pendiente ( $m$ ) indica cuánto cambia Y por cada unidad que cambia X.

El intercepto ( $b$ ) es el valor de Y cuando  $X = 0$  (el punto donde la recta corta el eje Y).

## Método de los mínimos cuadrados

Busca la recta que minimiza la suma de los cuadrados de los errores verticales:

$$SSE = \sum (y_i - \hat{Y}_i)^2 = \sum e_i^2 \quad e_i = y_i - \hat{Y}_i$$

Las fórmulas para los parámetros son:

$$m = \frac{\sum (x_i - \bar{X})(y_i - \bar{Y})}{\sum (x_i - \bar{X})^2}$$

$$m = \frac{n \sum xy - \sum x \sum y}{n \sum x^2 - (\sum x)^2}$$

$$b = \bar{Y} - m\bar{X}$$

$$b = \frac{\sum y - m \sum x}{n}$$

## Ejemplo numérico

Datos:

X: 1, 2, 3

Y: 2, 3, 5

$$\sum x = 1 + 2 + 3 = 6$$

$$\sum y = 2 + 3 + 5 = 10$$

$$\sum xy = 2 + 6 + 15 = 23$$

$$\sum x^2 = 1 + 4 + 9 = 14$$

$$\sum y^2 = 4 + 9 + 25 = 38$$

$$n = 3$$

$$m = \frac{3(23) - 6(10)}{3(14) - (6)^2} = 1.5$$

$$b = \frac{10 - 1.5(6)}{3} = 0.33$$


El método de mínimos cuadrados encuentra:

$$m = 1.5$$

$$b = 0.33$$

Ecuación de la recta final:

$$\hat{Y} = 1.5x - 0.33$$



# Coeficiente de correlación $r$

El coeficiente clásico es:  Coeficiente de correlación de Pearson ( $r$ )

Valor de $r$	Interpretación
0 a 0.3	Correlación débil
0.3 a 0.7	Correlación moderada
0.7 a 1.0	Correlación fuerte
0	No hay correlación
$r$ negativo	Relación inversa

Fórmula general de  $r$  (Pearson):

$$r = \frac{\sum (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum (x_i - \bar{X})^2 \sum (y_i - \bar{Y})^2}}$$

# Coeficiente de correlación $r$

$$r = \frac{\sum (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum (x_i - \bar{X})^2 \sum (y_i - \bar{Y})^2}}$$

Donde:

- $x_i$  y  $y_i$  son los datos individuales
- $\bar{x}$  es la media de X
- $\bar{y}$  es la media de Y
- La suma se hace sobre todos los pares  $(x_i, y_i)$

El numerador mide **cómo varían juntas** las dos variables.

El denominador normaliza la expresión para que el resultado siempre quede entre  $-1$  y  $1$ .

# Coeficiente de correlación $r$

Fórmula práctica:

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}}$$

Esta fórmula es más fácil de usar con tablas de datos.

## Coeficiente de determinación $R^2$

$$R^2 = r^2$$

Fórmula general en regresión lineal simple:

$$R^2 = 1 - \frac{SSE}{SST}$$

Donde:

SST es la suma total de cuadrados (variación total de Y)

SSE es la suma de cuadrados de los errores (lo que el modelo no explica)

$$SST = \sum (y_i - \bar{y})^2$$

$$SSE = \sum (y_i - \hat{y}_i)^2 = \sum e_i^2$$

## Ejemplo 1

Datos:

$$X = \{2, 4, 6\}$$

$$Y = \{3, 6, 9\}$$

1. Calcular el coeficiente de correlación.
  2. Calcular el coeficiente de determinación.
- 

Formula para calcular el coeficiente de correlación:

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}}$$

Formula para calcular el coeficiente de determinación:

$$R^2 = r^2$$

## Ejemplo 1

Datos:

$$X = \{2, 4, 6\}$$

$$Y = \{3, 6, 9\}$$

$$\sum x = 2 + 4 + 6 = 12$$

$$\sum y = 3 + 6 + 9 = 18$$

$$\sum xy = 6 + 24 + 54 = 84$$

$$\sum x^2 = 4 + 16 + 36 = 56$$

$$\sum y^2 = 9 + 36 + 81 = 126$$

$$n = 3$$

## Ejemplo 1


X	Y	XY	X <sup>2</sup>	Y <sup>2</sup>
2	3	6	4	9
4	6	24	16	36
6	9	54	36	81
Sumas → 12	18	84	56	126

$$r = \frac{3(84) - (12)(18)}{\sqrt{[3(56) - (12)^2][3(126) - (18)^2]}} = \frac{36}{\sqrt{1296}} = \frac{36}{36} = 1$$

$$R^2 = r^2 = 1$$

## Ejemplo 1

### Correlación lineal



$r = 1 \rightarrow$  correlación lineal perfecta.

## Ejemplo 2

En un laboratorio se midió la absorbancia de una solución de un colorante a distintas concentraciones:

Ensayo	Concentración (mg/L) X	Absorbancia (u.a.) Y
1	1	2.1
2	2	2.9
3	3	3.7
4	4	4.1
5	5	5.0

Se pide:

- Calcular la recta de regresión lineal de Y sobre X usando mínimos cuadrados.
- Interpretar los valores de m y b en el contexto.
- Estimar la absorbancia cuando la concentración es 3.5 mg/L.

## Cálculo de la recta de regresión (mínimos cuadrados)

X	Y	XY	X <sup>2</sup>
1	2.1	2.1	1
2	2.9	5.8	4
3	3.7	11.1	9
4	4.1	16.4	16
5	5.0	25.0	25

Sumas:

- $n = 5$
- $\sum X = 1 + 2 + 3 + 4 + 5 = 15$
- $\sum Y = 2.1 + 2.9 + 3.7 + 4.1 + 5.0 = 17.8$
- $\sum XY = 2.1 + 5.8 + 11.1 + 16.4 + 25.0 = 60.4$
- $\sum X^2 = 1 + 4 + 9 + 16 + 25 = 55$

**Pendiente  $m$ :** 
$$m = \frac{n \sum XY - (\sum X)(\sum Y)}{n \sum X^2 - (\sum X)^2} \quad m = \frac{35}{50} = 0.70$$

**Intercepto  $b$ :** 
$$b = \frac{\sum Y - m \sum X}{n} \quad b = \frac{7.3}{5} = 1.46$$


**Ecuación final de la recta:** 
$$\hat{Y} = 0.70X + 1.46$$

**Predicción para  $X = 3.5$  mg/L**

Usamos la recta: 
$$\hat{Y} = 0.70X + 1.46$$

Para  $X = 3.5$ : 
$$\hat{Y} = 0.70(3.5) + 1.46 \quad \hat{Y}(3.5) \approx 3.91$$

**Respuesta:** La absorbancia esperada a 3.5 mg/L es aproximadamente 3.91 unidades.



## Ejemplo práctico. Curva de calibración de Fe<sup>2+</sup>

Se obtiene la absorbancia de soluciones estándar de hierro en un espectrofotómetro UV-Vis.

Concentración (mg/L)	Absorbancia
0.20	0.09
0.40	0.20
0.60	0.31
0.80	0.40
1.00	0.51

Paso 1. Calculamos las medias:

$$\bar{X} = \frac{0.20 + 0.40 + 0.60 + 0.80 + 1.00}{5} = 0.60$$

$$\bar{Y} = \frac{0.09 + 0.20 + 0.31 + 0.40 + 0.51}{5} = 0.302$$

(X)	(Y)	XY	X <sup>2</sup>
0.20	0.09	0.018	0.04
0.40	0.20	0.08	0.16
0.60	0.31	0.186	0.36
0.80	0.40	0.32	0.64
1.00	0.51	0.51	1.00
3.0	1.51	1.114	2.20

Paso 2. Calculamos la pendiente y el intercepto:

$$m = \frac{n \sum xy - \sum x \sum y}{n \sum x^2 - (\sum x)^2} = \frac{5(1.114) - 3.0(1.51)}{5(2.20) - (3.0)^2} = 0.52$$

$$b = \frac{\sum y - m \sum x}{n} = \frac{1.51 - (0.52)3.0}{5} = -0.01$$

Paso 3. Ecuación de la recta:

$$\hat{Y} = 0.52 X - 0.01$$

Paso 5. Coeficiente de correlación (r)

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} = 0.998$$

El valor de r cercano a 1 indica una correlación lineal positiva casi perfecta.

Paso 6. Coeficiente de determinación

$$R^2 = r^2 = (0.998)^2 = 0.996$$

**Interpretación:** El 99.6% de la variabilidad de la absorbancia se explica por la concentración.

## Ejemplo 1

(X)	1	2	3	4	5
(Y)	2.0	2.8	3.6	4.5	5.1

1. Ajustar la recta de regresión.
  2. Calcular el coeficiente de correlación  $r$ .
  3. Calcular el coeficiente de determinación  $R^2$ .
  4. Interpretar el resultado con ayuda de las gráficas.
-

Calculamos las medias:

$$\bar{X} = \frac{1 + 2 + 3 + 4 + 5}{5} = 3$$

$$\bar{Y} = \frac{2.0 + 2.8 + 3.6 + 4.5 + 5.1}{5} = 3.6$$

Calculamos la pendiente:

$$m = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2}$$

Calculamos el intercepto:

$$b = \bar{Y} - m\bar{X}$$

Calculamos la pendiente:

$$m = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2}$$

(X)	(Y)	$X_i - \bar{X}$	$Y_i - \bar{Y}$	$(X_i - \bar{X})(Y_i - \bar{Y})$	$(X_i - \bar{X})^2$
1	2.0	-2.0	-1.6	3.2	4.0
2	2.8	-1.0	-0.8	0.8	1.0
3	3.6	0.0	0.0	0.0	0.0
4	4.5	1.0	0.9	0.9	1.0
5	5.1	2.0	1.5	3.0	4.0
				7.9	10.0

$$m = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2} = \frac{7.9}{10.0} = 0.79$$

Calculamos el intercepto:

$$b = \bar{Y} - m\bar{X} = 3.6 - 0.79 \cdot 3 = 1.23$$

Ajustamos una recta  $\hat{Y} = mx + b$  a esos datos.

Entonces la recta de regresión es:  $\hat{Y} = 0.79x + 1.23$

Con ella calculamos los valores predichos  $\hat{Y}$  para cada X.

(X)	(Y)	$\hat{Y} = 0.79x + 1.23$
1	2.0	$\hat{Y} = 0.79(1) + 1.23 = 2.02$
2	2.8	$\hat{Y} = 0.79(2) + 1.23 = 2.81$
3	3.6	$\hat{Y} = 0.79(3) + 1.23 = 3.60$
4	4.5	$\hat{Y} = 0.79(4) + 1.23 = 4.39$
5	5.1	$\hat{Y} = 0.79(5) + 1.23 = 5.18$


Calculamos el coeficiente de correlación  $r$ :

$$r = \frac{\sum(x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum(x_i - \bar{X})^2 \sum(y_i - \bar{Y})^2}}$$

(X)	(Y)	$X_i - \bar{X}$	$Y_i - \bar{Y}$	$(X_i - \bar{X})(Y_i - \bar{Y})$	$(X_i - \bar{X})^2$	$(Y_i - \bar{Y})^2$
1	2.0	-2.0	-1.6	3.2	4.0	2.56
2	2.8	-1.0	-0.8	0.8	1.0	0.64
3	3.6	0.0	0.0	0.0	0.0	0.0
4	4.5	1.0	0.9	0.9	1.0	0.81
5	5.1	2.0	1.5	3.0	4.0	2.25
				7.90	10.0	6.26

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2}} = \frac{7.9}{\sqrt{10 \cdot 6.26}} = \frac{7.9}{7.912} = 0.9985$$

# Ejemplo: Datos y recta de regresión



Calculamos el coeficiente de determinación  $R^2$ .

$$R^2 = 1 - \frac{SSE}{SST}$$

Para eso, necesitamos los valores de SST y SSE:

$$SST = \sum (Y_i - \bar{Y})^2$$

$$SSE = \sum (Y_i - \hat{Y}_i)^2 = \sum e_i^2$$

(Y)	$Y_i - \bar{Y}$	$(Y_i - \bar{Y})^2$	Residuos: $e_i = Y_i - \hat{Y}_i$	$e_i^2$
2.0	-1.6	2.56	$2.00 - 2.02 = -0.02$	$(-0.02)^2 = 0.0004$
2.8	-0.8	0.64	$2.80 - 2.81 = -0.01$	$(-0.01)^2 = 0.0001$
3.6	0.0	0.00	$3.60 - 3.60 = 0.00$	$(0.00)^2 = 0$
4.5	0.9	0.81	$4.50 - 4.39 = 0.11$	$(0.11)^2 = 0.0121$
5.1	1.5	2.25	$5.10 - 5.18 = -0.08$	$(-0.08)^2 = 0.0064$
		6.26		0.019

$$SST = \sum (Y_i - \bar{Y})^2 = 6.26$$

$$SSE = \sum (Y_i - \hat{Y}_i)^2 = \sum e_i^2 = 0.019$$

Coeficiente de determinación:

$$R^2 = 1 - \frac{SSE}{SST} = 1 - \frac{0.019}{6.26} = 0.997$$

Interpretación


$R^2 = 0.997$  significa que:

- El 99.7 % de la variación de Y es explicada por la recta de regresión y solo el 0.3 % se debe a ruido o factores no incluidos en el modelo.
- Es un ajuste casi perfecto, típico de un ejemplo de libro o de una buena curva de calibración en laboratorio.

El coeficiente de determinación se puede también calcular directamente:

$$R^2 = r^2 = (0.9985)^2 = 0.997$$

# Residuos del modelo



# **Significación estadística del modelo lineal**

Cuando ajustamos una regresión lineal:

$$\hat{Y} = mx + b$$

no basta con obtener la recta.

También debemos responder una pregunta fundamental:

**¿La relación lineal entre X y Y existe realmente,  
o es solo producto del azar?**

A eso se le llama **significación estadística del modelo lineal**.

## ¿Qué significa que un modelo lineal sea “estadísticamente significativo”?

Significa que:

- La pendiente  $m$  es distinta de cero de manera suficientemente clara como para concluir que sí existe una relación entre  $X$  y  $Y$  en la población.

En términos matemáticos, se evalúa la hipótesis:

$$H_0 : m = 0 \quad (\text{no hay relación})$$

$$H_a : m \neq 0 \quad (\text{sí hay relación})$$

Si al realizar la prueba estadística obtenemos un valor **p pequeño**, típicamente:

$$p < 0.05$$

entonces **rechazamos  $H_0$**  y concluimos:

**“La relación lineal entre  $X$  y  $Y$  es significativa.”**

## ¿Cómo se evalúa esta significación?

Existen varios indicadores, y todos apuntan a la misma conclusión:

- A) Prueba  $t$  para la pendiente
- B) ANOVA de la regresión (prueba  $F$ )
- C) Coeficiente de determinación  $R^2$

## A) Prueba t para la pendiente

La pendiente  $m$  calculada por mínimos cuadrados viene acompañada de:

- su error estándar  $SE(m)$ ,
- un estadístico  $t$ ,
- y su correspondiente valor  $p$ .

La fórmula general:

$$t = \frac{m}{SE(m)}$$

Un valor  $|t|$  grande  $\rightarrow$  relación significativa.

$SE(m)$  es el **error estándar de la pendiente** del modelo lineal.

## B) ANOVA de la regresión (prueba F)

Se utiliza la razón F:

$$F = \frac{\textit{Explicado por el modelo}}{\textit{No explicado (error)}}$$

Si  $p_F < 0.05$ ,  $\rightarrow$  *El modelo completo es significativo*

## C) Coeficiente de determinación $R^2$

Aunque  $R^2$  no es una prueba en sí, sí indica cuánta variación explica el modelo.

Reglas aproximadas:

$R^2 > 0.80 \rightarrow$  *relación fuerte*

$R^2 \sim 0.50 \rightarrow$  *relación moderada*

$R^2 < 0.20 \rightarrow$  *relación débil, aunque podría ser significativa con  $n$  grande*

 **OJO:**

Un  $R^2$  bajo NO implica que la relación no sea significativa estadísticamente.

Ejemplo común: datos biológicos con mucha variabilidad natural.

# Interpretación práctica

Si el modelo lineal es estadísticamente significativo, significa:

- Sí existe una relación real entre X y Y.
- La pendiente estimada ( $m$ ) es confiable.
- El modelo puede hacerse generalizable a la población.
- Las predicciones basadas en la recta tienen fundamento estadístico.

Si NO es estadísticamente significativo:

- El modelo no es válido.
- X NO explica Y.
- La pendiente podría ser indistinguible de cero.
- No debemos usar la regresión para predecir.

## Ejemplo sencillo (conceptual)

Supón que ajustas:

$$\hat{Y} = 3.2x + 2.1$$

y el software reporta:

- $m = 3.2$
- $SE(m) = 0.9$
- $t = 3.55$
- $p = 0.008$
- $R^2 = 0.78$

### Interpretación:

- $p < 0.05 \rightarrow$  la pendiente es significativa.
- Existe una relación positiva entre X y Y.
- $R^2 = 0.78 \rightarrow$  78% de la variación es explicada por el modelo.
- El modelo es útil para predicción.

# Conclusión

La significación estadística del modelo lineal nos permite responder si:

- La relación entre  $X$  y  $Y$  es real, y no resultado del azar.
- Podemos confiar en la recta ajustada como una descripción válida del fenómeno.
- Es apropiado hacer predicciones usando ese modelo.
- Es el “sello de validez” de la regresión.

## Ejemplo con datos reales (empresa de consumo)

Semana	Publicidad (X) (miles \$)	Ventas (Y) (miles unidades)
1	5	55
2	8	60
3	12	63
4	15	70
5	18	74
6	22	80
7	25	82
8	30	90
9	35	95
10	40	102

La pregunta es: **¿La publicidad realmente explica las ventas?**  
¿El modelo lineal es estadísticamente significativo?

## Ajuste de la recta de regresión usando mínimos cuadrados

$$m = 1.25$$

$$b = 48.84$$

Ecuación de la recta final:  $\hat{Y} = 1.25 x + 48.84$

**Interpretación:** Cada 1 mil pesos adicionales en publicidad  $\rightarrow$  las ventas aumentan 1,250 unidades.

**Cálculo del coeficiente de determinación  $R^2$**

$$R^2 = 0.972$$

**Interpretación:** El 97.2% de la variación de las ventas es explicada por el gasto en publicidad. Esto ya sugiere una relación muy fuerte.

## Significación estadística del modelo

El análisis estadístico del modelo lineal entrega:

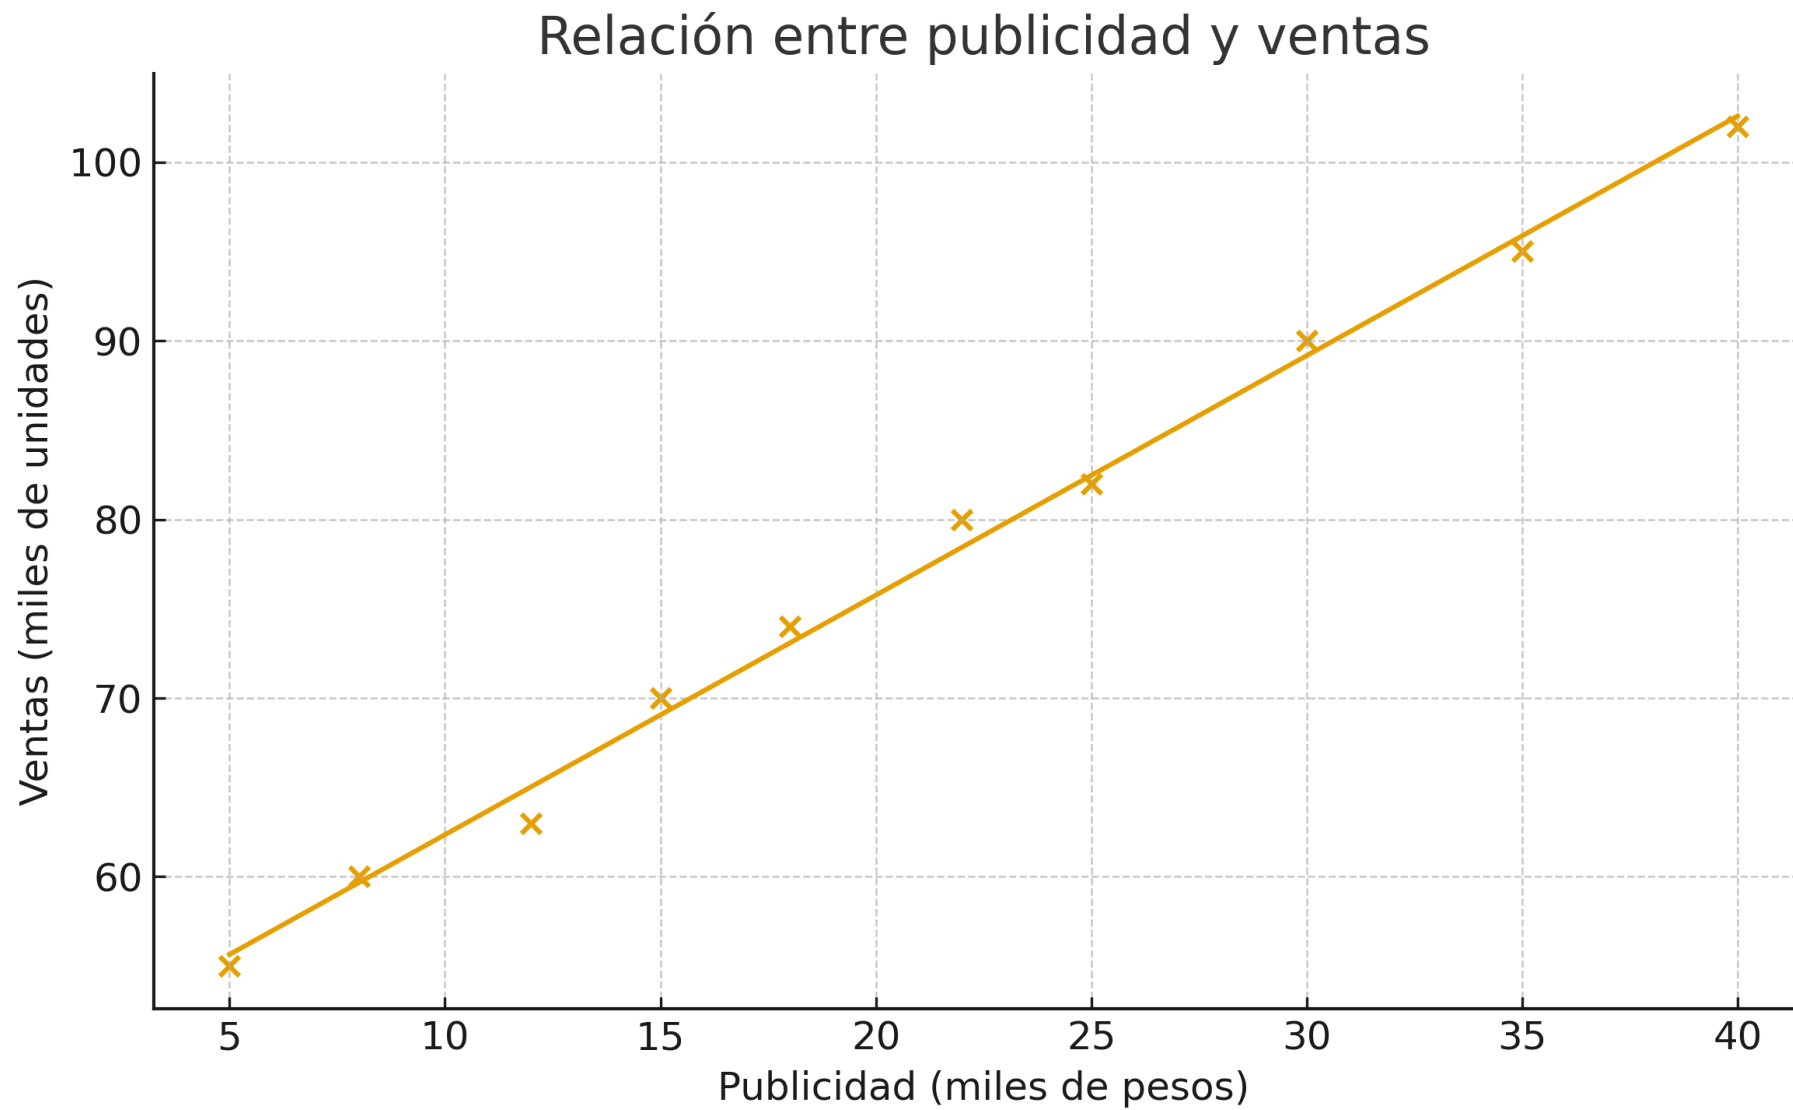
- Estadístico  $F = 280.3$
- $p$ -value asociado = 0.0000008

Como:  $p < 0.05$ , Concluimos que:

El modelo lineal es estadísticamente significativo.

La relación entre publicidad y ventas sí existe en la población.

# Gráfica de la relación (interpretación visual)



## Tabla ANOVA del modelo (interpretada)

Fuente	SC (Suma de Cuadrados)	gl	CM	F	p-value
Modelo	2311.5	1	2311.5	280.3	0.0000008
Error	68.0	8	8.5	—	—
Total	2379.5	9	—	—	—

Interpretación:

- Casi toda la variación está en la parte explicada por el modelo.
- La F es enorme → evidencia muy fuerte de relación lineal.

## Conclusión del ejemplo

- La publicidad sí explica las ventas.
- El modelo lineal no es producto del azar ( $p$  muy pequeño).
- $R^2 = 0.972$  indica una relación muy fuerte.
- El modelo puede usarse para predicción con alta confianza.

### Ejemplo de predicción:

Si se invierten 50 mil pesos en publicidad:

$$\hat{Y} = 1.25 (50) + 48.84 = 110.34$$

Se esperan aprox. 110 mil unidades vendidas.

## Ejemplo: Curva de calibración espectrofotométrica

Se quiere cuantificar un fármaco por espectrofotometría UV–Vis a una longitud de onda específica. Se preparan soluciones estándar y se mide la absorbancia.

### Datos experimentales:

Ensayo	Concentración (X) (mg/L)	Absorbancia (Y) (u.a.)
1	0	0.02
2	1	0.19
3	2	0.40
4	3	0.61
5	4	0.79
6	5	1.02
7	6	1.19

## Ajuste del modelo lineal

Se ajusta una recta de calibración:

$$\hat{Y} = mx + b$$

Usando mínimos cuadrados (por ejemplo en Excel /otro software), se obtiene:

$$m = 0.199$$

$$b = 0.007$$

Ecuación de la recta final:  $\hat{Y} = 0.199 x + 0.007$

**Interpretación de  $m$** : Por cada incremento de 1 mg/L en concentración, la absorbancia aumenta aproximadamente 0.199 unidades.

**Coeficiente de determinación:**  $R^2 = 0.999$

**Interpretación:** El 99.9 % de la variación de la absorbancia se explica por la concentración. Es un ajuste excelente, típico de una buena curva de calibración en su rango lineal.

### **Significación estadística del modelo**


En un software de análisis (Excel, Origin, etc.) verías:

- p-valor de la pendiente  $m \ll 0.05$
- F de la regresión muy grande

### **Conclusión:**

- El modelo lineal es estadísticamente significativo.
- La relación “concentración–absorbancia” es real, no producto del azar.
- Por lo tanto, se puede usar la ecuación para determinar concentraciones desconocidas a partir de su absorbancia.

# Curva de calibración espectrofotométrica



## Curva de calibración obtenida

$$\hat{Y} = 0.199 x + 0.007$$

Supongamos que se mide la absorbancia de una muestra desconocida y se obtiene:

$$A_{muestra} = 0.72$$

Necesitamos encontrar su concentración.  $A = \pi r^2$  —

---

Sustituimos en la ecuación:

$$\begin{aligned} A &= 0.199 x + 0.007 \\ 0.72 &= 0.199 x + 0.007 \end{aligned}$$

$$x = 3.58 \text{ mg/L}$$

## Resultado

$$X_{muestra} = 3.58 \text{ mg/L}$$

## Verificación rápida

$$\hat{Y} = 0.199 (3.58) + 0.007 = 0.713 + 0.007 = 0.720$$

## Ejemplo con muestras fuera del rango lineal.

Ensayo	Concentración (X) (mg/L)	Absorbancia (Y) (u.a.)
1	0	0.02
2	1	0.19
3	2	0.40
4	3	0.61
5	4	0.79
6	5	1.02
7	6	1.19

$$\hat{A} = 0.199 x + 0.007$$

El laboratorio valida que la región lineal útil de la curva es:  $0 \leq X \leq 6 \text{ mg/L}$

Se mide la absorbancia de una muestra problema sin diluir y se obtiene:

$$A_{muestra} = 1.45$$

Pregunta:

- ¿Es válido usar directamente la ecuación de calibración para calcular la concentración a partir de  $A = 1.45$  ?

Si ignoráramos el rango lineal y usáramos:

$$\hat{A} = 0.199 x + 0.007 \quad \rightarrow \quad X \sim 7.25 \text{ mg/L}$$

PEROOOO... El rango lineal validado es hasta 6 mg/L.

Estamos **fuera del rango lineal** de la curva.

### **Conclusión:**

- No es válido confiar en este valor.
- El instrumento y el sistema ya no garantizan linealidad arriba de 6 mg/L.
- El resultado directo de 7.25 mg/L es **sospechoso y potencialmente sesgado.**



**Prueba de hipótesis e intervalos  
de confianza para los parámetros  
de la línea recta.**

Este es uno de los temas más importantes en regresión lineal, porque permite:

- Evaluar si la relación entre  $X$  y  $Y$  realmente existe.
- Determinar si la pendiente es distinta de cero.
- Estimar la recta verdadera de la población con un intervalo de confianza.

# 1. Modelo de regresión lineal simple

Trabajamos con el modelo:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Donde:

$\beta_0 = \textit{intercepto poblacional}$

$\beta_1 = \textit{pendiente poblacional}$

$\varepsilon = \textit{error aleatorio}$

En la muestra obtenemos los estimadores:

$b_0$  para  $\beta_0$

$b_1$  para  $\beta_1$

## 2. Prueba de hipótesis para la pendiente $\beta_1$

La pregunta es: **¿Existe relación lineal entre X y Y en la población?**

Esto se evalúa mediante una **prueba t**:

$H_0: \beta_1 = 0$  (no hay relación lineal)

$H_1: \beta_1 \neq 0$  (si hay relación lineal)

Estadístico t:  $t = \frac{b_1}{SE(b_1)}$

$SE(b_1)$  es el error estándar de la pendiente

### Decisión

- Si  $|t|$  es grande  $\rightarrow$  evidencia contra  $H_0$
- Si  $p < \alpha$  (generalmente 0.05)  $\rightarrow$  se rechaza  $H_0$

### Conclusión

Si se rechaza  $H_0$ :

Existe una relación lineal significativa entre X y Y.

### 3. Prueba de hipótesis para el intercepto $\beta_0$

$$H_0: \beta_0 = 0$$

$$H_1: \beta_0 \neq 0$$

$$t = \frac{b_0}{SE(b_0)}$$

- Aunque es menos importante que la pendiente, se utiliza para validar ciertos modelos
- (p. ej., curvas de calibración que se “obligan” a pasar por el origen).

## 4. Intervalos de confianza para los parámetros

Los parámetros estimados  $b_0$  y  $b_1$  **NO son exactos**:

son estimaciones con variabilidad muestral.

Por eso se construyen intervalos de confianza:

### Intervalo de confianza del 95% para la pendiente $\beta_1$

$$b_1 \pm t_{\alpha/2, n-2} \cdot SE(b_1)$$

#### Interpretación:

El 95% de todas las rectas poblacionales posibles tienen pendientes dentro de este intervalo.

### Intervalo de confianza del 95% para el intercepto $\beta_0$

$$b_0 \pm t_{\alpha/2, n-2} \cdot SE(b_0)$$

# Interpretación general de los intervalos

Para la pendiente:

- Si el intervalo incluye 0, entonces la pendiente podría ser 0 → NO hay evidencia de relación lineal.
- Si el intervalo NO incluye 0, entonces la pendiente es distinta de 0 → SÍ hay relación lineal significativa.

Para el intercepto:

- Si incluye 0, no es necesariamente un problema.
- En calibración analítica, un intercepto muy lejos de 0 indica problemas del método.

## Ejemplo numérico

Supongamos que en un análisis se obtuvo:

- $b_1 = 2.5$
- $SE(b_1) = 0.6$
- $n = 12$  puntos experimentales
- Nivel de confianza 95%

Con  $gl = n - 2 = 10$ :

$$t_{0.025,10} = 2.228$$

Intervalo de confianza:

$$IC = 2.5 \pm 2.228(0.6)$$

$$IC = 2.5 \pm 1.3368$$

$$IC = (1.163, 3.837)$$

Interpretación:

- La pendiente **no incluye 0** →  
Existe una relación lineal significativa.
- La verdadera pendiente poblacional se encuentra entre **1.16 y 3.84** con 95% de confianza.

## Ejemplo. Datos de calibración

Se prepara una serie de soluciones estándar de un analito y se mide su absorbancia UV–Vis:

Ensayo	Concentración (X) (mg/L)	Absorbancia (Y) (u.a.)
1	0.0	0.01
2	1.0	0.21
3	2.0	0.39
4	3.0	0.61
5	4.0	0.80
6	5.0	1.02

1. Ajustar el modelo lineal  $\hat{Y} = m x + b$ .
2. Hacer prueba de hipótesis para la pendiente  $\beta_1$ .
3. Hacer prueba de hipótesis para el intercepto  $\beta_0$ .
4. Construir intervalos de confianza al 95 % para  $\beta_1$  y  $\beta_0$ .
5. Ver la gráfica.

# 1. Ajuste de la recta de regresión

Con mínimos cuadrados se obtiene:

- Pendiente estimada:

$$m = b_1 \approx 0.2011$$

- Intercepto estimado:

$$b = b_0 \approx 0.0038$$

Ecuación de regresión:

$$\hat{Y} = 0.2011X + 0.0038$$

Interpretación de  $m$ :

Cada aumento de **1 mg/L** en concentración incrementa la absorbancia en aproximadamente **0.201 unidades**.

## 2 Calidad del ajuste: $R^2$

Calculando SST, SSR y SSE se obtiene:

$$R^2 \approx 0.9993$$

El **99.93** % de la variación de la absorbancia se explica por la concentración.  
Excelente linealidad, apropiada para una curva de calibración.

### 3 Prueba de hipótesis para la pendiente $\beta_1$

#### Hipótesis

$$H_0 : \beta_1 = 0 \quad (\text{no hay relación lineal})$$

$$H_a : \beta_1 \neq 0 \quad (\text{sí hay relación lineal})$$

#### Error estándar de la pendiente

$$SE(b_1) \approx 0.00270$$

#### Estadístico t

$$t_{\text{calc}} = \frac{b_1}{SE(b_1)} = \frac{0.2011}{0.00270} \approx 74.48$$


Con  $gl = 4$  y  $\alpha = 0.05$  (bilateral), el valor crítico es:

$$t_{0.025,4} \approx 2.776$$

Como:

$$|t_{\text{calc}}| = 74.48 \gg 2.776$$

$\Rightarrow$  se rechaza  $H_0$ .

 **Conclusión:**

La pendiente es altamente significativa.

Existe una relación lineal muy fuerte entre concentración y absorbancia.

#### 4 Prueba de hipótesis para el intercepto $\beta_0$

Hipótesis

$$H_0 : \beta_0 = 0$$

$$H_a : \beta_0 \neq 0$$

Error estándar del intercepto

$$SE(b_0) \approx 0.00818$$

Estadístico t

$$t_{\text{calc}} = \frac{b_0}{SE(b_0)} = \frac{0.0038}{0.00818} \approx 0.466$$

Comparamos con el mismo valor crítico  $t_{0.025,4} = 2.776$ :

$$|t_{\text{calc}}| = 0.466 < 2.776$$

⇒ NO se rechaza  $H_0$ .

✦ **Conclusión:**

El intercepto **no es significativamente diferente de 0**.

Es razonable considerar que, a concentración cero, la absorbancia real podría ser muy cercana a cero (compatible con la ley de Beer-Lambert).

## 5 Intervalos de confianza al 95 %

a) Para la pendiente  $\beta_1$

$$IC_{95\%}(\beta_1) = b_1 \pm t_{0.025,4} \cdot SE(b_1)$$

$$IC_{95\%}(\beta_1) = 0.2011 \pm 2.776 \times 0.00270$$

$$IC_{95\%}(\beta_1) \approx (0.1936, 0.2086)$$

✓ La pendiente es claramente positiva y bien acotada; el intervalo **no incluye 0**.

b) Para el intercepto  $\beta_0$


$$IC_{95\%}(\beta_0) = b_0 \pm t_{0.025,4} \cdot SE(b_0)$$

$$IC_{95\%}(\beta_0) = 0.0038 \pm 2.776 \times 0.00818$$

$$IC_{95\%}(\beta_0) \approx (-0.0189, 0.0265)$$

✓ Este intervalo sí incluye 0, coherente con la prueba t:  
el intercepto podría ser 0 en la población.

Curva de calibración: datos y recta ajustada



**Explorar gráficos de tendencia y  
linealización de modelos en Excel.**

## A) Modelo exponencial

$$Y = ae^{bX}$$

Ejemplos:

- cinética de primer orden
- crecimiento bacteriano
- degradación de fármacos

Transformación:

$$\ln Y = \ln a + bX$$



## B) Modelo de potencia

$$Y = aX^b$$

Ejemplos:

- procesos biológicos
- leyes de escala
- difusión
- viscosidad vs temperatura

Transformación:

$$\ln Y = \ln a + b \ln X$$



## C) Modelo logarítmico

$$Y = a \ln X + b$$

Usado en:

- procesos que crecen rápido al inicio y luego se estabilizan
- química ambiental

No requiere transformación adicional.

## D) Modelo cinético de primer orden (muy típico en QFB)

$$\ln A = -kt + \ln A_0$$

Ejemplos:

- degradación de medicamentos
- cinética de reacciones simples
- oxidación en alimentos

Se linealiza graficando:

$t$  vs  $\ln A$

## E) Modelo Michaelis–Menten

$$v = \frac{V_{max}S}{K_m + S}$$

Opciones de linealización:

- Lineweaver–Burk
- Hanes–Wolf
- Eadie–Hofstee



