

# Análisis de la asociación espacial

Regresión


---


Gerardo Martín

2022-06-29


- Correlación mide dependencia lineal entre dos fenómenos
- No hay causa - efecto:
  - $\text{cov}(X, Y) = \text{cov}(Y, X)$
- No permite estimar cambio de una con respecto de la otra
- Regresión, sí se asume causa y efecto:
  - $y(x) = a + bx$

- Correlación, sólo conocemos  $r$ , ó  $\rho$  (correlación de Spearman)
  - Signo de  $r$  indica si una disminuye ó aumenta en relación a la otra
  - $P$  indica probabilidad de que  $r = 0$
- Regresión
  - Coeficientes  $a$  y  $b$  cuantifican relación entre  $x$  y  $y$
  - $a$ , valor de  $y$  cuando  $x = 0$
  - $b$ , aumento ó disminución de  $y$  cuando  $x$  aumenta en 1 unidad
  - $R^2$ , cuadrado del coeficiente de correlación  $r$







## Diferencias gráficas



## Diferencias gráficas



# Significato de parámetros





$$y(x) = a + bx$$

- $a = 2$

- $b = i/h = 0.5$

$$y(x) = 2 + 0.5x$$

- Función nativa para estimar  $a$ ,  $b$  y  $R^2$ , `lm`
- Hipótesis que queremos rechazar,  $x$  no afecta a  $y$ 
  - $a \neq 0, b \neq 0$
- Uso:

```
lm(x ~ y, data = df.1) #df.1 es tabla que contiene datos de x
```

## Implementando en R

```
reg.lin <- lm(y ~ x, data = df.1)
summary(reg.lin)

##
## Call:
## lm(formula = y ~ x, data = df.1)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -2.6090  -0.8366  -0.0884   0.6772   3.4914
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept) -6.20626    0.58606  -10.59  <2e-16 ***
## x            1.10859    0.05621   19.72  <2e-16 ***
## ---
```

### Columnas

- `Estimate` contiene el valor estimado
- `Pr(>|t|)` es la probabilidad de que  $a = 0$  ó  $b = 0$

### Filas

- $a = (\text{Intercept})$
- $b = x$
- $R^2 = \text{Adjusted R - squared}$

## Implementando en R

```
reg.lin1 <- lm(y ~ x1, data = df.1)
summary(reg.lin1)

##
## Call:
## lm(formula = y ~ x1, data = df.1)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -5.4589 -1.2876 -0.2732  1.3428  8.3563
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept)  5.13185    0.24895  20.614  <2e-16 ***
## x1           0.09689    0.25581   0.379   0.706
## ---
```

Al igual que en correlación, debemos:

1. Extraer
2. Añadir a base de coordenadas
3. Ajustar
4. Interpretar
5. Predecir

Retomaremos el ejemplo de la correlación espacial:

**Table 1:** Primeras seis filas de una base de datos de mediciones colectadas en campo.

x	y	mediciones
-102.7928	29.57881	49.62024
-103.6011	27.38053	41.14992
-104.5670	25.53772	137.04156
-101.8276	29.87109	51.70786
-100.5730	27.40428	103.70981
-101.0474	29.20245	75.43274

## Gráfico de los valores colectados




Figure 1: Diámetro de burbujas indica magnitud



```
valores.capas <- extract(r, puntos[, c("x", "y")])  
puntos <- data.frame(puntos, valores.capas)
```

## Valores extraídos de capa raster

x	y	mediciones	Var.1	Var.2	Var.3
-102.7928	29.57881	49.62024	199	106	161
-103.6011	27.38053	41.14992	179	105	143
-104.5670	25.53772	137.04156	187	126	193
-101.8276	29.87109	51.70786	203	105	149
-100.5730	27.40428	103.70981	224	135	143
-101.0474	29.20245	75.43274	213	121	131
-102.5358	28.58792	35.05952	174	101	132
-101.4132	28.86275	69.94669	209	125	134
-102.3974	26.52351	92.91473	211	134	153
-102.6020	25.42059	131.78474	218	147	148

Con base en análisis de correlación sabemos que es más probable que `Var.2` explique las mediciones:

```
m1 <- lm(mediciones ~ Var.2, puntos)
```

## Ajustando el modelo lineal


```
summary(m1)

##
## Call:
## lm(formula = mediciones ~ Var.2, data = puntos)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -70.751 -13.179  -0.278  13.347  56.566
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept) -160.5896    18.0366  -8.904 3.12e-14 ***
## Var.2         2.0531     0.1505  13.641 < 2e-16 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Necesitamos crear base con valores para predecir:

```
val.nuevos <- data.frame(rasterToPoints(r))  
preds <- predict(m1, val.nuevos)  
preds.r <- rasterFromXYZ(data.frame(val.nuevos[, c("x", "y")])
```

## Gráfico de la predicción



```
m2 <- lm(mediciones ~ Var.1, puntos)
m3 <- lm(mediciones ~ Var.3, puntos)
```

## Comparación con otros modelos

```
##  
## Call:  
## lm(formula = mediciones ~ Var.1, data = puntos)  
##  
## Residuals:  
##      Min       1Q   Median       3Q      Max   
## -87.153 -17.571  -3.082  18.632  70.786   
##  
## Coefficients:  
##              Estimate Std. Error t value Pr(>|t|)      
## (Intercept) -193.0459    39.1002  -4.937 3.30e-06 ***  
## Var.1         1.3950     0.1966   7.096 2.12e-10 ***  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
##
```



## Comparación con otros modelos

```
##  
## Call:  
## lm(formula = mediciones ~ Var.3, data = puntos)  
##  
## Residuals:  
##      Min       1Q   Median       3Q      Max   
## -108.501  -31.980    2.111   24.895   85.851   
##  
## Coefficients:  
##              Estimate Std. Error t value Pr(>|t|)      
## (Intercept)  59.1195    35.5229   1.664   0.0993 .      
## Var.3         0.1614     0.2335   0.691   0.4913   
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
##
```

```
AIC(m1)
```

```
## [1] 900.5037
```

```
AIC(m2)
```

```
## [1] 965.1384
```

```
AIC(m3)
```

```
## [1] 1006.045
```

Modelo con AIC menor, **m1**, por lo tanto, parece más adecuado que **m2** y **m3**

- Regresión lineal sirve para predecir
- Correlación sirve para medir asociación