

Aspectos geométricos de la regresión y correlación lineal

Juan-Bosco Romero Márquez,
María de los Ángeles López y Sánchez-Moreno

Resumen

Con este trabajo elemental de investigación en el aula presentamos como una experiencia el estudio del problema: LA REGRESIÓN Y LA CORRELACIÓN LINEAL DE UNA VARIABLE ESTADÍSTICA BIDIMENSIONAL Y EL SIGNIFICADO GEMOÉTRICO, utilizando para ello las propiedades elementales del trinomio de segundo grado y su gráfica, que es una parábola, y la traslación de ejes de coordenadas, evitando con ello el cálculo con derivadas.

Al final damos una aplicación a la geometría del plano.

Abstract

In this article we presents some geometric topics over the regression and correlation lineal in the secondary teaching.

Introducción

Comenzamos enunciando el siguiente problema.

Problema.- Sea la variable estadística bidimensional (X, Y) donde X e Y son variables estadísticas unidimensionales, de la que conocemos la distribución conjunta de puntos, $P_i(x_i, y_i)$, con $i = 1, \dots, n$

Queremos encontrar e interpretar las rectas de regresión lineal de y sobre x , dada por $y = b x + a$, y la recta de regresión lineal de x sobre y , dada por $x = b' y + a'$, utilizando como criterio de optimización el de mínimos cuadrados, para determinarlas como las curvas de ajuste o aproximación de la nube de puntos P_i , $i = 1, \dots, n$.

Es decir: calcular las rectas de regresión lineal de tal forma que la desviación cuadrática, de y sobre x , como de x sobre y , que están dadas, respectivamente, por las fórmulas:

$$S(a, b) = \sum_{i=1}^n (y_i - (a + b x_i))^2 \quad (I), \quad (y \text{ sobre } x), \quad y$$

$$S(a', b') = \sum_{i=1}^n (x_i - (a' + b' y_i))^2 \quad (2), \quad (x \text{ sobre } y),$$

sean mínimas.

Basta resolver el problema para el caso (1), ya que el caso (2), se resolverá por simetría intercambiando los papeles de las variables.

Observación: A la desviación cuadrática definida anteriormente, también se le llama error cuadrático.

Resultados previos

Los alumnos deben conocer y manejar completamente los siguientes conceptos y resultados:

a) La función cuadrática $y = f(x) = ax^2 + bx + c$, donde $a, b, c, \in \mathbb{R}$, con a no nulo y cuya gráfica es una parábola con eje de simetría vertical, y con las ramas hacia arriba (cóncava) si $a > 0$, y con las ramas hacia abajo (convexa), si $a < 0$.

Los resultados anteriores son consecuencia del estudio del signo de la función cuadrática, $y = ax^2 + bx + c$, y de sus propiedades algebraicas y geométricas elementales, en su dominio, \mathbb{R}

a₁) El vértice, V , de la parábola viene dado por:

$V(-b/2a, f(-b/2a))$, que es, el punto mínimo o máximo absoluto de la función o de la parábola, respectivamente, para $a > 0$, y $a < 0$.

a₂) Dada la variable estadística X , cuyos valores dados son $x_i, i = 1, 2, \dots, n$.

Definimos $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$, (3), la media aritmética de los datos, $x_i, i = 1, 2, \dots, n$.

Definimos el error de un dato x_i , con respecto a la media \bar{x} , o con respecto a un dato arbitrario x , por las expresiones:

$d_i = x_i - \bar{x}$, o, $d_i(x) = x_i - x$. Es claro que puede ocurrir que la suma de todos los errores anteriores puede dar cero. Por esta causa esta suma de errores o desviaciones no es significativa para estudiar las propiedades de la media aritmética, \bar{x} .

Para caracterizar la media aritmética, \bar{x} , necesitamos definir el error cuadrático de los errores $d = x - \bar{x}, i = 1, 2, \dots, n$, de las desviaciones de los datos x_i , con respecto a la media, \bar{x} , como sigue: