

coeficiente de correlación – correlation coefficient

Authored by
memjavad

November 25, 2025

RECOMMENDED CITATION

memjavad (2025). *coeficiente de correlación – correlation coefficient*. Spanish Psychological Databases. Retrieved from <https://spanish.arabpsychology.com/?p=6058>

Coeficiente de Correlación

Primary Disciplinary Field(s): Estadística, Matemáticas, Econometría, Psicometría, Ciencias de Datos

1. Definición Central y Propósito

El coeficiente de correlación es una medida estadística fundamental diseñada para cuantificar la fuerza y la dirección de la relación lineal o monótona entre dos variables aleatorias. Representa, en esencia, un índice estandarizado que permite a los investigadores determinar hasta qué punto los cambios en una variable se asocian consistentemente con los cambios en otra. Este concepto es central en la estadística descriptiva e inferencial, sirviendo como una herramienta esencial para la exploración inicial de los datos y la formulación de modelos predictivos o explicativos.

Su propósito principal radica en proporcionar una métrica única y fácilmente interpretable que resuma la naturaleza de la interdependencia observada en un conjunto de datos bivariado. Un coeficiente de correlación no solo indica si las variables se mueven juntas (relación positiva) o en direcciones opuestas (relación negativa), sino que también asigna un valor numérico que califica la intensidad de dicha asociación. Esta estandarización es crucial, ya que permite comparar la fuerza de las relaciones entre diferentes pares de variables, independientemente de sus unidades de medida originales o de la escala en la que se recolectaron los datos.

La aplicación del coeficiente de correlación abarca prácticamente todas las disciplinas científicas, desde la física y la biología hasta las finanzas y las ciencias sociales. Por ejemplo, en economía, puede utilizarse para evaluar la relación entre la tasa de desempleo y la inflación; en psicología, para medir la consistencia interna de un instrumento de medición o la asociación entre dos rasgos de personalidad. La versatilidad del coeficiente lo convierte en uno de los primeros pasos metodológicos al analizar la estructura de las variables en cualquier estudio empírico, facilitando la identificación de patrones y la reducción de la dimensionalidad de los problemas.

2. Etimología y Desarrollo Histórico

El concepto de correlación, y la necesidad de cuantificar la interdependencia de las variables, tiene sus raíces históricas en los estudios de la herencia y la variación biológica de finales del siglo XIX. Aunque la idea de que dos fenómenos podían estar relacionados era antigua, la formalización matemática de esta relación se atribuye principalmente a los pioneros de la estadística moderna. La palabra **correlación** en sí misma surgió como un término técnico para describir la co-relación o la relación mutua entre características.

El desarrollo más significativo fue impulsado por Sir [Francis Galton](#), quien, en sus estudios sobre la herencia de características físicas como la altura en humanos, observó y documentó el

fenómeno de la "regresión a la media". Galton notó que los hijos de padres muy altos tendían a ser más altos que el promedio, pero no tanto como sus padres, mostrando una relación imperfecta que denominó "co-relación". Su trabajo sentó las bases conceptuales, aunque la formulación matemática precisa aún estaba pendiente.

Fue el estadístico [Karl Pearson](#), un colega y continuador de la obra de Galton, quien formalizó y popularizó la fórmula que hoy se conoce como el coeficiente de correlación producto-momento, o **coeficiente de Pearson (r)**. Pearson, a través de una serie de artículos influyentes a finales del siglo XIX y principios del XX, estableció la metodología rigurosa para calcular este coeficiente, convirtiéndolo en la herramienta estándar para medir la asociación lineal. La contribución de Pearson fue fundamental porque proporcionó una fórmula que estandarizaba la covarianza, limitando el valor resultante al rango de -1 a +1, lo que facilitaba su interpretación universal.

3. Tipos Principales de Coeficientes

Existen diversos coeficientes de correlación, cada uno adecuado para diferentes tipos de datos y supuestos sobre la naturaleza de la relación entre las variables. La elección del coeficiente apropiado depende crucialmente del nivel de medición de las variables (nominal, ordinal o de intervalo/razón) y de si se cumplen o no los supuestos de normalidad y linealidad.

El tipo más conocido y utilizado es el **coeficiente de correlación producto-momento de Pearson (r)**. Este coeficiente está diseñado específicamente para medir la fuerza y la dirección de una relación **lineal** entre dos variables de escala de intervalo o razón, asumiendo que ambas variables siguen una distribución aproximadamente normal. Es sensible a la magnitud de las diferencias entre las variables, basándose en el cálculo de la covarianza dividida por el producto de las desviaciones estándar.

Cuando los datos son de naturaleza ordinal o cuando los supuestos paramétricos de Pearson no se cumplen (por ejemplo, en presencia de datos con distribuciones no normales o valores atípicos extremos), se recurre a coeficientes no paramétricos. Los más destacados son el **coeficiente de correlación de rangos de Spearman (rho o ρ)** y el **coeficiente de correlación tau de Kendall (τ)**. Estos coeficientes se basan en el ranking de las observaciones en lugar de sus valores brutos. Miden la fuerza de la relación **monótona** (es decir, si las variables tienden a aumentar o disminuir juntas, sin requerir que esta relación sea estrictamente lineal), lo que los hace robustos ante transformaciones monótonas de los datos.

Para casos especiales, como la correlación entre una variable dicotómica (binaria) y una variable continua, se puede utilizar el **coeficiente biserial puntual**. Si ambas variables son dicotómicas, se emplea el **coeficiente Phi (ϕ)**. Si bien estos coeficientes operan bajo principios similares de cuantificación de la asociación, su interpretación y sus supuestos matemáticos varían significativamente, lo que subraya la necesidad de seleccionar la métrica adecuada según el

contexto de la investigación.

4. Interpretación y Rango de Valores

Una de las características más útiles del coeficiente de correlación es su rango estandarizado, que siempre se encuentra entre -1 y +1, inclusive. Esta estandarización permite una interpretación directa y universal de la fuerza y la dirección de la asociación, independientemente de la escala original de las variables analizadas. La interpretación se basa en tres aspectos clave: el signo, la magnitud y la significación.

El **signo** del coeficiente determina la dirección de la relación. Un coeficiente positivo ($r > 0$) indica una **correlación positiva**: a medida que los valores de una variable aumentan, los valores de la otra variable también tienden a aumentar. Un coeficiente negativo ($r < 0$) indica una **correlación negativa** o inversa: a medida que los valores de una variable aumentan, los valores de la otra variable tienden a disminuir. Un coeficiente cercano a cero ($r \approx 0$) sugiere que no existe una relación lineal o monótona detectable entre las variables.

La **magnitud** (el valor absoluto) del coeficiente indica la fuerza de la relación. Un valor de +1.0 o -1.0 representa una **correlación perfecta**, donde todos los puntos de datos caen exactamente sobre una línea recta (en el caso de Pearson) o siguen un orden monótono exacto (en el caso de Spearman o Kendall). Cuanto más se acerca el valor absoluto a 1, más fuerte es la asociación. Por el contrario, valores cercanos a 0 indican una relación débil o inexistente. Es importante notar que, aunque existen guías generales (por ejemplo, $|r| > 0.7$ es fuerte, $|r| < 0.3$ es débil), la interpretación de la fuerza debe ser contextualizada dentro del campo de estudio específico; una correlación de 0.5 puede ser considerada muy fuerte en las ciencias sociales, pero débil en la física.

La interpretación también debe considerar el **coeficiente de determinación (R^2)**, que es el cuadrado del coeficiente de correlación de Pearson. Este valor, expresado como porcentaje, indica la proporción de la varianza total en una variable que puede ser explicada por la varianza en la otra variable. Por ejemplo, si $r = 0.60$, entonces $R^2 = 0.36$, lo que significa que el 36% de la variabilidad en la variable dependiente es atribuible a la relación lineal con la variable independiente. Este valor ofrece una interpretación práctica del impacto de la correlación.

5. El Coeficiente de Correlación de Pearson (r)

El coeficiente de correlación producto-momento de Pearson es la medida de correlación más utilizada y se define formalmente como la razón entre la **covarianza** de las dos variables y el producto de sus desviaciones estándar. Matemáticamente, el coeficiente de Pearson, r_{xy} , se calcula mediante la fórmula:

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}$$

Esta formulación asegura que el coeficiente es una medida pura de asociación lineal, libre de las unidades de medida originales. El numerador (la covarianza) mide el grado en que las variables varían conjuntamente. Si los valores de X y Y se desvían de sus respectivas medias en la misma dirección, la covarianza es positiva; si se desvían en direcciones opuestas, es negativa. El denominador (el producto de las desviaciones estándar) actúa como un factor de normalización, asegurando que el resultado final se mantenga dentro del rango .

El uso del coeficiente de Pearson está sujeto a varios supuestos paramétricos importantes. Primero, requiere que la relación entre las variables sea **lineal**; si la relación es curvilínea (por ejemplo, en forma de U invertida), el coeficiente de Pearson subestimarán gravemente la verdadera fuerza de la asociación. Segundo, se asume que las variables están medidas en una escala de intervalo o razón. Tercero, y de manera crucial para la inferencia estadística, se asume que las variables siguen una distribución bivariada normal. La violación de estos supuestos, especialmente la no linealidad, puede llevar a conclusiones erróneas sobre la inexistencia de una relación cuando, de hecho, existe una relación no lineal fuerte.

A pesar de sus supuestos restrictivos, el coeficiente de Pearson sigue siendo la base de gran parte del análisis multivariado, incluyendo el análisis de regresión lineal. Es una medida robusta bajo condiciones ideales y proporciona una base teórica sólida para comprender cómo la variación en una variable se propaga a la otra, siempre y cuando se verifique visualmente la linealidad a través de diagramas de dispersión.

6. Coeficientes Basados en Rangos: Spearman y Kendall

Cuando los datos no cumplen con los requisitos de Pearson, o cuando la naturaleza de la información es intrínsecamente ordinal, se emplean coeficientes de correlación no paramétricos. Los más prominentes en esta categoría son el coeficiente de correlación de rangos de Spearman y el coeficiente tau de Kendall, desarrollados para medir la asociación monótona.

El **coeficiente de Spearman** (ρ) se calcula aplicando la fórmula de Pearson a los rangos de los datos en lugar de a los valores brutos. Es decir, primero se ordenan y se asignan rangos a cada variable por separado, y luego se calcula la correlación entre esos rangos. Esto tiene la ventaja de que el coeficiente no es sensible a la distribución de los datos ni a la presencia de valores atípicos, ya que la magnitud de un valor extremo solo afecta su rango, no la diferencia cuadrática que se utiliza en la fórmula. Spearman mide la fuerza de la relación monótona: si una variable tiende a aumentar a medida que la otra aumenta, la correlación de rangos será alta, incluso si la relación no es perfectamente lineal.

El **coeficiente tau de Kendall** (τ) es otra medida no paramétrica que se enfoca en la probabilidad

de que dos variables observadas estén en el mismo orden (pares concordantes) versus la probabilidad de que estén en órdenes diferentes (pares discordantes). Kendall es a menudo preferido en casos de tamaños de muestra pequeños o cuando hay un gran número de empates en los rangos. Aunque ambos, Spearman y Kendall, miden la asociación monótona, Kendall tiende a ser más robusto y tiene una interpretación probabilística más clara, aunque su valor absoluto es típicamente menor que el de Spearman para el mismo conjunto de datos.

La elección entre Pearson, Spearman y Kendall es una decisión metodológica crucial. Si el objetivo es modelar una relación lineal precisa y los datos lo permiten, Pearson es el estándar. Si se busca simplemente determinar si existe una tendencia consistente (creciente o decreciente) sin asumir linealidad o normalidad, Spearman o Kendall son las alternativas adecuadas. Ambos coeficientes basados en rangos son herramientas poderosas para el análisis de datos robusto en disciplinas como la psicología, la sociología y la ecología, donde los datos a menudo no cumplen con los estrictos supuestos paramétricos.

7. Significación Estadística y Pruebas de Hipótesis

Aunque un coeficiente de correlación puede indicar una asociación fuerte en una muestra de datos, es esencial determinar si esta asociación es estadísticamente significativa, es decir, si es probable que la correlación observada exista también en la población de la que se extrajo la muestra. Esto se logra mediante pruebas de hipótesis.

La hipótesis nula (H_0) en la prueba de correlación típicamente establece que la correlación poblacional (ρ) es igual a cero ($\rho = 0$), lo que implica que no existe una relación lineal entre las variables en la población. La hipótesis alternativa (H_1) establece que la correlación es diferente de cero ($\rho \neq 0$). Para el coeficiente de Pearson, se utiliza una prueba t de Student para determinar la probabilidad (valor p) de observar una correlación muestral tan extrema como la calculada, asumiendo que la hipótesis nula es verdadera.

Si el valor p resultante es menor que el nivel de significancia preestablecido (típicamente $\alpha = 0.05$), se rechaza la hipótesis nula, concluyendo que la correlación observada es estadísticamente significativa. Es decir, hay evidencia suficiente para afirmar que existe una relación no nula en la población. Sin embargo, es vital recordar que la significación estadística es diferente de la significación práctica. Una correlación muy pequeña (por ejemplo, $r = 0.1$) puede ser estadísticamente significativa si el tamaño de la muestra es extremadamente grande, pero puede tener poco valor práctico o explicativo.

Además de la prueba de significación, es fundamental calcular los **intervalos de confianza** para el coeficiente de correlación poblacional. Debido a que la distribución muestral del coeficiente r no es normal, especialmente cuando el valor poblacional de ρ está lejos de cero, se utiliza la transformación de Fisher (transformación z) para aproximar la distribución a una normal. Esto

permite construir un intervalo dentro del cual se espera que caiga el verdadero valor de ρ en la población con un cierto nivel de confianza (por ejemplo, 95%). Un intervalo de confianza que no incluye el cero refuerza la conclusión de la significación estadística.

8. Limitaciones y Advertencias (Causalidad vs. Correlación)

La limitación más crítica y frecuentemente malinterpretada del coeficiente de correlación es que **correlación no implica causalidad**. Un coeficiente de correlación alto solo indica que dos variables se mueven juntas de manera predecible, pero no ofrece ninguna información sobre si una variable influye directamente en la otra, ni la dirección de esa influencia. Ignorar esta distinción es una falacia lógica común que puede llevar a conclusiones científicas o políticas incorrectas.

Existen varias razones por las cuales una correlación fuerte puede no ser causal. La más común es la presencia de una **tercera variable (o variable de confusión)**. Dos variables X e Y pueden estar fuertemente correlacionadas porque ambas están influenciadas por una variable Z no observada. Por ejemplo, el número de helados consumidos (X) puede correlacionar fuertemente con el número de ahogamientos (Y), pero la causa subyacente (Z) es la temperatura ambiente, que impulsa tanto el consumo de helados como la natación. Sin un diseño experimental riguroso o métodos estadísticos avanzados (como el modelado de ecuaciones estructurales), la correlación por sí sola no puede desentrañar la causalidad.

Otra limitación importante es la susceptibilidad de los coeficientes, especialmente el de Pearson, a los **valores atípicos (outliers)** y a la **restricción de rango**. Un solo punto de datos extremo puede inflar o deflactar drásticamente el valor de r . De manera similar, si los datos recolectados solo cubren un rango muy limitado de los valores posibles de las variables, el coeficiente de correlación calculado a partir de esa muestra restringida tenderá a ser menor de lo que sería si se observara el rango completo de la población, lo que puede subestimar la verdadera relación.

Finalmente, el coeficiente de Pearson solo mide la relación lineal. Si la verdadera relación entre las variables es curvilínea (por ejemplo, cuadrática o exponencial), el valor de r puede ser cercano a cero, sugiriendo falsamente la ausencia de relación. Por lo tanto, el análisis de correlación nunca debe realizarse sin una inspección visual previa de los datos a través de un diagrama de dispersión, lo que permite detectar patrones no lineales, valores atípicos y problemas de heterogeneidad o restricción de rango.

Lectura Adicional

[Coeficiente de correlación de Pearson - Wikipedia](#)

[Pearson, K. \(1896\). Mathematical Contributions to the Theory of Evolution. III. Regression, Heredity and Panmixia. Philosophical Transactions of the Royal Society of London. A, 187.](#)

[253-318.](#)

[Correlación de rangos de Spearman - Wikipedia](#)

[Correlación y dependencia - Wikipedia](#)

ARABPSYCHOLOGY.COM