

coeficiente de determinación – coefficient of determination

Authored by
memjavad

November 17, 2025

RECOMMENDED CITATION

memjavad (2025). *coeficiente de determinación – coefficient of determination*. Spanish Psychological Databases. Retrieved from <https://spanish.arabpsychology.com/?p=4935>

Coeficiente de Determinación (R^2)

Primary Disciplinary Field(s): Estadística, Econometría, Aprendizaje Automático

1. Definición Central

El **coeficiente de determinación**, denotado universalmente como R^2 (R-cuadrado), constituye una medida fundamental en el análisis estadístico, particularmente dentro del contexto de la **regresión lineal** y sus extensiones. Su propósito primordial es cuantificar la proporción de la variabilidad total de la variable dependiente (o de respuesta) que es explicada o predecida por el modelo de regresión que incorpora variables independientes (o predictoras). En esencia, R^2 evalúa la bondad de ajuste de un modelo, indicando qué tan bien las observaciones reales se ajustan a los valores predichos por la línea de regresión. Un valor de R^2 cercano a 1 sugiere que el modelo explica una gran parte de la varianza en la respuesta, mientras que un valor cercano a 0 indica que el modelo no ofrece una mejora significativa sobre un modelo nulo que simplemente utiliza la media de la variable dependiente como predicción.

Formalmente, el coeficiente de determinación se define como el cociente entre la suma de cuadrados de la regresión (SSR, por sus siglas en inglés, que representa la variabilidad explicada por el modelo) y la suma total de cuadrados (SST, que representa la variabilidad total de los datos). Esta relación matemática lo posiciona como un indicador estandarizado, siempre confinado al intervalo entre 0 y 1, si se asume que la regresión incluye un término de intercepto y se ajusta mediante el método de mínimos cuadrados ordinarios (MCO). La robustez y la ubicuidad del R^2 radican en su capacidad para proporcionar una métrica única y fácilmente interpretable sobre la calidad predictiva del modelo, facilitando la comparación entre diferentes formulaciones de modelos que buscan explicar el mismo fenómeno dependiente.

Es crucial entender que el R^2 no evalúa si el modelo está sesgado, si los coeficientes son significativos, o si las suposiciones subyacentes de la regresión (como la normalidad de los residuos o la homocedasticidad) se cumplen. Su enfoque es puramente descriptivo respecto a la varianza explicada. Por lo tanto, un alto R^2 no implica necesariamente causalidad ni garantiza que el modelo sea el mejor para la predicción, sino simplemente que las variables predictoras incluidas logran capturar una porción sustancial de la dispersión observada en los datos de respuesta. La [interpretación contextual](#) es vital, ya que un R^2 considerado "bueno" puede variar drásticamente entre disciplinas; por ejemplo, en la física experimental, se esperan valores muy cercanos a 1, mientras que en la economía o las ciencias sociales, un valor de 0.3 puede considerarse altamente significativo.

2. Origen Histórico y Desarrollo

Aunque la **regresión lineal** tiene raíces que se remontan a los trabajos pioneros de Sir Francis Galton y Karl Pearson a finales del siglo XIX, la formalización y el uso sistemático de una métrica que cuantificara la bondad de ajuste, similar al R^2 moderno, se consolidaron en el desarrollo de la estadística moderna. El concepto de correlación, estrechamente ligado al R^2 , fue establecido por Pearson, quien desarrolló el coeficiente de correlación r (el Coeficiente de Correlación de Pearson). En el caso de la regresión lineal simple (con una sola variable predictora), el coeficiente de determinación R^2 es, de hecho, simplemente el cuadrado del coeficiente de correlación de Pearson, r^2 .

El desarrollo del R^2 como una herramienta estándar en la regresión múltiple se debe en gran medida a la necesidad de extender la idea de correlación a modelos con múltiples predictores. Su adopción se popularizó con la difusión de los métodos de mínimos cuadrados y la creciente capacidad de realizar cálculos complejos, especialmente después de la mitad del siglo XX, con la introducción de los ordenadores. La formulación específica que descompone la varianza total en varianza explicada y varianza residual se convirtió en el estándar de oro para evaluar modelos, proporcionando una métrica intuitiva para investigadores en campos tan diversos como la agricultura, la biología y, notablemente, la econometría. La estandarización de esta métrica permitió la comunicación clara de los resultados del modelado en la literatura académica.

Es importante notar que mientras el concepto subyacente de la varianza explicada es antiguo, la terminología y la notación R^2 se volvieron omnipresentes a medida que los paquetes de software estadístico (como SAS, SPSS y, posteriormente, R y Python) adoptaron la métrica como una salida estándar para cualquier análisis de regresión. Esto solidificó su posición no solo como una medida teórica, sino como un elemento práctico indispensable en la evaluación de modelos predictivos y explicativos, facilitando la comprensión y el reporte de la fuerza de las relaciones modeladas.

3. Fundamentos Matemáticos: La Descomposición de la Varianza

La comprensión profunda del coeficiente de determinación requiere analizar la descomposición de la varianza total de la variable dependiente, Y . Esta descomposición se basa en el principio de que la desviación de cualquier observación individual (y_i) respecto a la media muestral (\bar{y}) puede ser dividida en dos componentes ortogonales: la desviación explicada por el modelo (la diferencia entre el valor predicho \hat{y}_i y la media \bar{y}) y el error residual (la diferencia entre el valor observado y_i y el valor predicho \hat{y}_i). Matemáticamente, esto se expresa como: $(y_i - \bar{y}) = (\hat{y}_i - \bar{y}) + (y_i - \hat{y}_i)$.

Al elevar al cuadrado y sumar estas desviaciones a lo largo de todas las observaciones, se obtiene la identidad fundamental de la regresión por mínimos cuadrados: la Suma Total de Cuadrados (SST) es igual a la Suma de Cuadrados de la Regresión (SSR) más la Suma de

Cuadrados del Error (SSE). La **SST** representa la variabilidad total de Y , es decir, la variación que existiría si no se utilizara ninguna variable predictora. La **SSR** cuantifica la mejora en la predicción obtenida al usar el modelo de regresión en lugar de la media muestral. La **SSE** mide la variabilidad no explicada por el modelo, es decir, el error residual, que el modelo no ha logrado capturar.

La fórmula del coeficiente de determinación se deriva directamente de esta identidad: $R^2 = \text{SSR} / \text{SST} = 1 - (\text{SSE} / \text{SST})$. Esta formulación demuestra que R^2 mide qué tan cerca está la SSE de cero. Si SSE es cero, significa que todos los puntos de datos caen exactamente sobre la línea de regresión, por lo que $\text{SSR} = \text{SST}$, y $R^2 = 1$. Si, por otro lado, el modelo de regresión no ofrece ninguna mejora sobre la simple media (es decir, $\hat{y}_i = \bar{y}$ para todas las i), entonces SSR es cero, y $\text{SSE} = \text{SST}$, resultando en $R^2 = 0$. Esta estructura matemática garantiza que el valor de R^2 sea inherentemente una proporción de la varianza total que ha sido efectivamente capturada por la función lineal del modelo.

4. Interpretación y Rango de Valores

El R^2 es una métrica de fácil interpretación, lo que contribuye a su popularidad. Si un modelo de regresión arroja un valor de $R^2 = 0.65$, se interpreta que el 65% de la variación total en la variable dependiente es predecible a partir de las variables independientes incluidas en el modelo. El 35% restante de la variabilidad se atribuye a factores no incluidos en el modelo, errores de medición o varianza inherente e inexplicable (ruido). Es fundamental comunicar este porcentaje en términos de varianza explicada, evitando implicaciones de causalidad directa.

Como se mencionó previamente, el rango canónico de R^2 es de 0 a 1. Sin embargo, es fundamental recalcar que este rango solo está garantizado si se cumplen dos condiciones metodológicas: primero, que el modelo de regresión incluye un término de intercepto (constante); y segundo, que los parámetros del modelo se estiman utilizando el método de **mínimos cuadrados ordinarios** (MCO). Estas condiciones aseguran que la suma de cuadrados de los residuos (SSE) no exceda la suma total de cuadrados (SST), manteniendo la relación de proporción válida.

Si se viola la primera condición, por ejemplo, al forzar un modelo a pasar por el origen (regresión sin intercepto), o si se utilizan métodos de estimación distintos a MCO, es matemáticamente posible obtener un R^2 negativo. Un [valor de \$R^2\$ negativo](#), aunque anómalo en el contexto estándar, indica que el modelo ajustado es peor que el modelo de referencia más simple (aquel que usa la media), sugiriendo que las predicciones del modelo son, en promedio, peores que simplemente adivinar la media de la variable dependiente. Esto sirve como una fuerte advertencia de que la especificación del modelo es fundamentalmente incorrecta o inadecuada.

5. Variantes y Extensiones: El R Cuadrado Ajustado

Una limitación crítica del R^2 estándar es que, por construcción matemática, su valor nunca puede disminuir cuando se añaden nuevas variables predictoras al modelo, incluso si estas variables no tienen una relación estadísticamente significativa con la variable dependiente. El R^2 estándar es susceptible al sobreajuste (overfitting), ya que la adición de predictores, aunque sean ruido puro, siempre reducirá ligeramente la Suma de Cuadrados del Error (SSE), inflando artificialmente el valor de R^2 . Para mitigar este problema, los estadísticos desarrollaron el **coeficiente de determinación ajustado** (R^2_{adj}).

El R^2 ajustado penaliza la inclusión de variables predictoras que no mejoran sustancialmente la capacidad explicativa del modelo. Lo logra incorporando los grados de libertad en su cálculo, ajustando tanto la SSE como la SST en función del número de predictores (k) y el tamaño de la muestra (n). La fórmula del R^2 ajustado es: $R^2_{\text{adj}} = 1 - \frac{\text{SSE}}{\text{SST}}$. Al dividir las sumas de cuadrados por sus respectivos grados de libertad, se transforma la métrica en un cociente de varianzas estimadas (varianza residual sobre varianza total). El R^2_{adj} solo aumentará si la nueva variable reduce la SSE lo suficiente como para compensar la pérdida de un grado de libertad. Si la variable añadida es inútil, el R^2_{adj} puede permanecer igual o incluso disminuir, y siempre será menor o igual al R^2 no ajustado.

Debido a esta característica de penalización por complejidad, el R^2 ajustado es la métrica preferida para la comparación de modelos de regresión que tienen diferente número de variables predictoras, especialmente cuando el objetivo es la inferencia o la parsimonia del modelo. Mientras que el R^2 estándar proporciona una medida de la bondad de ajuste del modelo a los datos de la muestra, el R^2 ajustado ofrece una estimación más honesta de cómo se comportaría el modelo si se aplicara a una nueva muestra de datos, mitigando el riesgo de seleccionar un modelo excesivamente complejo que solo se ajusta bien al ruido de los datos de entrenamiento. En la práctica, los investigadores suelen reportar ambos valores.

6. Aplicaciones en Modelos de Regresión

El coeficiente de determinación es una herramienta omnipresente en prácticamente todas las áreas de la investigación cuantitativa. En la **econometría**, se utiliza frecuentemente para evaluar modelos que predicen variables macroeconómicas como el Producto Interno Bruto (PIB) o la inflación. Un R^2 alto en un modelo econométrico puede indicar que las variables fiscales y monetarias seleccionadas son fuertes predictores de la variable económica de interés. Sin embargo, en esta disciplina, el R^2 debe ser complementado rigurosamente con pruebas de significancia de los coeficientes (pruebas t y F) y el diagnóstico de los supuestos del modelo, dada la naturaleza estocástica de los datos económicos.

En el campo del **aprendizaje automático** (Machine Learning), el R^2 es una métrica de

evaluación clave, especialmente para tareas de regresión. Se utiliza para medir el rendimiento de algoritmos como la regresión de Ridge, Lasso o los métodos de árboles de decisión. En ML, sin embargo, la evaluación se realiza típicamente en un conjunto de datos de prueba (que el modelo no ha visto previamente) para asegurar que el rendimiento no esté sesgado por el sobreajuste. Un R^2 alto en el conjunto de entrenamiento, pero bajo en el conjunto de prueba, es una señal clara de sobreajuste, reforzando la necesidad de utilizar validación cruzada y métricas robustas contra la generalización deficiente.

Además de la regresión lineal tradicional, el concepto de R^2 se ha extendido y adaptado a otros tipos de modelos estadísticos, aunque con modificaciones en su interpretación y cálculo. Por ejemplo, en los **modelos lineales generalizados** (GLM), como la regresión logística o de Poisson, donde la varianza no se descompone de la misma manera que en MCO debido a la función de enlace, se utilizan análogos denominados Pseudo R^2 (por ejemplo, el R^2 de McFadden o de Cox y Snell). Estos pseudo-coeficientes buscan imitar la interpretación del [R-cuadrado](#) estándar, midiendo la mejora del modelo propuesto sobre el modelo nulo, pero basándose en la función de verosimilitud en lugar de la suma de cuadrados. Es crucial que los investigadores especifiquen qué variante de pseudo R^2 están utilizando, ya que sus rangos y comparabilidad varían significativamente.

7. Limitaciones y Malas Interpretaciones

A pesar de su utilidad, el R^2 es frecuentemente malinterpretado, lo que puede llevar a conclusiones erróneas en la investigación. La limitación más grave es que el R^2 es una medida de asociación y no de causalidad. Un valor alto solo indica una fuerte relación lineal entre las variables, pero no prueba que las variables independientes sean la causa directa de los cambios en la variable dependiente. La confusión entre correlación y causalidad es quizás el error más común asociado a la interpretación del coeficiente de determinación; un R^2 alto puede ser el resultado de variables omitidas o de una relación espuria.

Otra mala interpretación común es asumir que un R^2 alto implica que las predicciones futuras del modelo serán precisas. El R^2 solo mide la bondad de ajuste dentro de la muestra de datos utilizada para entrenar el modelo. Si los datos futuros provienen de una distribución diferente (un fenómeno conocido como deriva de datos o 'data drift'), el modelo puede fallar estrepitosamente, independientemente de cuán alto fuera el R^2 original. Esto subraya la importancia de evaluar siempre la estabilidad del modelo y su capacidad de generalización en nuevos conjuntos de datos, lo cual es el objetivo principal del R^2 ajustado.

Finalmente, el R^2 es ineficaz para comparar modelos que utilizan diferentes transformaciones de la variable dependiente. Por ejemplo, si un investigador compara un modelo que predice Y con otro que predice $\log(Y)$, los valores de R^2 no son directamente comparables. Además,

el R^2 no proporciona información sobre si el modelo es el correcto en términos de especificación funcional. Dos modelos pueden tener un R^2 idéntico (por ejemplo, $R^2=0.50$), pero uno podría ser un modelo lineal apropiado y el otro podría ser un modelo cuadrático mal especificado que, por casualidad, ajusta la misma cantidad de varianza. Es imperativo que la evaluación del modelo siempre incluya el análisis de los gráficos de residuos para detectar patrones sistemáticos no capturados por el modelo, como la heterocedasticidad o la no linealidad.

8. Conclusión y Legado

El coeficiente de determinación, R^2 , se mantiene como una de las métricas más influyentes y citadas en el análisis estadístico y la modelización predictiva. Su legado reside en ofrecer una métrica estandarizada y altamente interpretable para evaluar la proporción de la variabilidad que puede ser atribuida a las relaciones lineales capturadas por el modelo de regresión. Desde su origen como una extensión de la correlación de Pearson hasta su adaptación en la econometría moderna y el aprendizaje automático, ha demostrado ser indispensable para resumir la fuerza de la relación predictiva de manera concisa.

No obstante, la evolución de la estadística ha enseñado que el R^2 nunca debe ser utilizado de forma aislada. Su utilidad se maximiza cuando se complementa con otras herramientas de diagnóstico, como el R^2 ajustado para la selección de modelos, el valor p de la prueba F para la significancia global del modelo, y el análisis gráfico de los residuos para verificar la validez de los supuestos subyacentes. La elección de un modelo óptimo es un proceso multifacético que requiere tanto la cuantificación de la varianza explicada (a través de R^2) como la confirmación de que el modelo es teóricamente sólido y estadísticamente válido, cumpliendo con los criterios de los [mínimos cuadrados ordinarios](#).

En última instancia, el R^2 sirve como un puente intuitivo entre la teoría y la práctica, permitiendo a los investigadores comunicar rápidamente la eficacia de sus modelos. Aunque ha sido objeto de críticas por sus limitaciones inherentes (especialmente su sensibilidad al sobreajuste y su incapacidad para indicar causalidad), el coeficiente de determinación sigue siendo el punto de partida esencial para cualquier evaluación de la bondad de ajuste en la regresión, manteniendo su relevancia como un pilar fundamental de la estadística aplicada y la ciencia de datos.

Further Reading

[Coeficiente de determinación \(Wikipedia\)](#)

[R-Squared Definition and Interpretation \(Investopedia\)](#)

[Regresión lineal \(Wikipedia\)](#)