

distribución de probabilidad bivariada – bivariate probability distribution

Authored by
memjavad

November 8, 2025

RECOMMENDED CITATION

memjavad (2025). *distribución de probabilidad bivariada – bivariate probability distribution*. Spanish Psychological Databases. Retrieved from <https://spanish.arabpsychology.com/?p=3400>

Distribución de Probabilidad Bivariada

Campo(s) Disciplinario(s) Principal(es): Estadística, Teoría de la Probabilidad, Econometría, Ciencia de Datos

1. Definición Central

Una distribución de [probabilidad bivariada](#) es una construcción fundamental dentro de la estadística y la teoría de la probabilidad que se utiliza para describir el comportamiento conjunto de dos **variables aleatorias** relacionadas, denotadas convencionalmente como X e Y . A diferencia de las distribuciones univariadas, que analizan el resultado de una única variable (como la altura o la temperatura), la distribución bivariada aborda cómo la probabilidad de un resultado específico para X depende o interactúa con el resultado de Y . Este marco es esencial para modelar sistemas complejos donde múltiples factores influyen simultáneamente en un fenómeno observado, permitiendo a los analistas ir más allá del estudio aislado de variables. La definición formal se basa en la asignación de probabilidades a todos los pares posibles de valores que (X, Y) pueden tomar, ya sea en un espacio discreto o continuo.

El concepto de distribución bivariada cobra vida a través de la **función de probabilidad conjunta** (para variables discretas) o la **función de densidad de probabilidad conjunta** (para variables continuas). Ambas funciones, $f(x, y)$, deben satisfacer dos condiciones básicas: primero, que todos los valores de la función deben ser no negativos, y segundo, que la suma (en el caso discreto) o la integral doble (en el caso continuo) de la función sobre todo el rango de valores posibles debe ser igual a uno. Esta unicidad en la probabilidad total refleja que el par de variables (X, Y) debe tomar necesariamente algún valor dentro del espacio muestral definido. La capacidad de capturar la interdependencia entre X e Y es lo que confiere a la distribución bivariada su inmenso poder analítico en campos que van desde la física hasta las finanzas.

Es crucial entender que la distribución bivariada proporciona la imagen completa, mientras que las distribuciones univariadas de X y Y por separado (conocidas como **distribuciones marginales**) solo ofrecen una vista parcial. Si bien las distribuciones marginales se pueden derivar de la distribución bivariada, el proceso inverso generalmente no es posible sin información adicional sobre la relación o **estructura de dependencia** entre las variables. Por lo tanto, el objetivo principal de trabajar con distribuciones bivariadas es caracterizar no solo las probabilidades individuales de X y Y , sino, fundamentalmente, la probabilidad de que X tome un valor x y simultáneamente Y tome un valor y .

2. Desarrollo Histórico y Contexto Matemático

Si bien los fundamentos de la teoría de la probabilidad se establecieron firmemente en los siglos

XVII y XVIII con figuras como Pascal, Fermat y Bernoulli, el desarrollo formal y sistemático de las distribuciones conjuntas, y específicamente las bivariadas, se consolidó en el siglo XIX y principios del XX. La necesidad de modelar errores de medición y fenómenos sociales complejos, donde múltiples factores de error o influencia actuaban conjuntamente, impulsó la formalización de herramientas que pudieran manejar la dependencia estocástica. El trabajo pionero en la estadística multivariada, que incluye la bivariada como su caso más simple, a menudo se asocia con la escuela biométrica y el desarrollo de la correlación por figuras como **Francis Galton** y **Karl Pearson**.

El concepto de **correlación**, introducido por Galton y formalizado matemáticamente por Pearson, sirvió como un puente crucial. Antes de la formulación explícita de las funciones de densidad conjuntas, la correlación ya ofrecía una medida numérica de la fuerza y dirección de la relación lineal entre dos variables. Este enfoque práctico sentó las bases para la necesidad teórica de una función matemática que describiera completamente la estructura de probabilidad subyacente, no solo su relación lineal. La distribución Normal Bivariada, que se convirtió en el arquetipo de las distribuciones conjuntas, fue fundamental en estos desarrollos iniciales, especialmente en la genética y la antropometría, donde se estudiaban pares de características heredadas simultáneamente.

El contexto matemático moderno de las distribuciones bivariadas está profundamente entrelazado con la **teoría de la medida** y el rigor matemático introducido por pensadores como Kolmogorov. La teoría moderna de la probabilidad define las variables aleatorias como funciones medibles y las distribuciones conjuntas como medidas de probabilidad en el espacio producto \mathbb{R}^2 . Este marco abstracto garantiza que las propiedades como la independencia estocástica y las distribuciones condicionales se definan de manera precisa y consistente, permitiendo la aplicación de estas herramientas a cualquier espacio de probabilidad, ya sea discreto, continuo o mixto.

3. Tipos de Distribuciones Bivariadas

Las distribuciones bivariadas se clasifican fundamentalmente según la naturaleza de las variables aleatorias X e Y que están modelando. Esta clasificación determina si se utiliza una función de probabilidad o una función de densidad, y qué técnicas de cálculo (sumas o integrales) son apropiadas para derivar propiedades.

El tipo más común es la **Distribución Bivariada Continua**. En este caso, ambas variables X e Y pueden tomar cualquier valor dentro de un rango continuo (por ejemplo, altura y peso). La distribución se describe mediante una función de densidad de probabilidad conjunta, $f(x, y)$, y las probabilidades de que las variables caigan dentro de una región específica del plano xy se calculan mediante la integración de esta función sobre dicha región. El ejemplo canónico es la **Distribución Normal Bivariada**, que es crucial en la inferencia estadística multivariada y modela

perfectamente fenómenos donde las variables están correlacionadas linealmente y sus marginales son normales.

En contraste, la **Distribución Bivariada Discreta** ocurre cuando ambas variables solo pueden tomar un número contable de valores (por ejemplo, el número de fallas en dos componentes distintos). Aquí, la distribución se define por una función de probabilidad conjunta, $P(X=x, Y=y)$, que asigna una probabilidad específica a cada par (x, y) posible. Ejemplos importantes incluyen la distribución **Binomial Bivariada** o la **Poisson Bivariada**, utilizadas para modelar conteos conjuntos de eventos que pueden estar relacionados.

Finalmente, existe la **Distribución Bivariada Mixta**. Este caso, menos común pero relevante en modelos especializados, ocurre cuando una variable es continua y la otra es discreta. Por ejemplo, modelar la cantidad de lluvia (continua) y si ocurrió o no un evento de inundación (discreta). La descripción matemática de estas distribuciones requiere una combinación de sumas e integrales, lo que añade una capa de complejidad al cálculo de sus propiedades.

4. Propiedades Clave: Marginalidad y Condicionalidad

Dos de las propiedades más importantes que se derivan de una distribución de probabilidad bivariada son las distribuciones marginales y las distribuciones condicionales. Estas propiedades permiten descomponer el comportamiento conjunto para entender los comportamientos individuales y las interacciones específicas.

La **Distribución Marginal** de X (o Y) se obtiene "marginalizando" o sumando (o integrando) la distribución conjunta sobre todos los valores posibles de la otra variable. Matemáticamente, si $f(x, y)$ es la densidad conjunta, la densidad marginal de X , $f_X(x)$, se calcula como $f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy$. Esta función describe la distribución de probabilidad de una de las variables como si la otra variable no existiera o fuera ignorada. Es la distribución univariada de X que resulta de la distribución conjunta.

La **Distribución Condicional**, por otro lado, es la herramienta esencial para entender la dependencia. La distribución condicional de Y dado que X ha tomado un valor específico x , denotada $f_{Y|X}(y|x)$, describe cómo se comporta Y una vez que se conoce el valor de X . Se calcula como el cociente de la densidad conjunta y la densidad marginal de la variable condicionante: $f_{Y|X}(y|x) = f(x, y) / f_X(x)$, siempre que $f_X(x) > 0$. Esta función es crucial en la inferencia estadística, ya que permite hacer predicciones probabilísticas sobre una variable basada en la observación de la otra. Por ejemplo, en regresión, el modelo se centra en la media de la distribución condicional.

Un concepto derivado directamente de estas propiedades es la **Independencia Estocástica**. Dos variables aleatorias X e Y son estadísticamente independientes si, y solo si, su función de

probabilidad conjunta es igual al producto de sus funciones marginales: $f(x, y) = f_X(x) \cdot f_Y(y)$ para todos los pares (x, y) . Si esta condición se cumple, la información sobre el valor de una variable no proporciona ninguna información sobre el valor de la otra. En el contexto condicional, esto implica que $f_{Y|X}(y|x)$ es simplemente $f_Y(y)$, es decir, la distribución de Y no cambia al conocer X.

5. Medidas de Asociación: Covarianza y Correlación

Mientras que la función de densidad conjunta describe completamente la relación probabilística, a menudo es necesario resumir la fuerza y la naturaleza de la dependencia utilizando medidas numéricas. La **covarianza** y el **coeficiente de correlación** son las medidas de asociación lineal más utilizadas en el contexto bivariado.

La **Covarianza**, $\text{Cov}(X, Y)$, mide la tendencia de X e Y a variar conjuntamente. Se define como el valor esperado del producto de las desviaciones de cada variable respecto a su media: $\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)]$. Un valor positivo de la [covarianza](#) indica que cuando X está por encima de su media, Y tiende a estar por encima de la suya, y viceversa. Un valor negativo indica que cuando una variable es alta, la otra tiende a ser baja. Un valor de covarianza de cero indica que no existe una relación lineal entre las variables. Sin embargo, la covarianza tiene la limitación de que su magnitud depende de las unidades de medida de X e Y, lo que dificulta su interpretación directa.

Para superar la dependencia de las unidades, se utiliza el **Coeficiente de Correlación de Pearson**, $\rho_{X, Y}$, que es una versión normalizada de la covarianza. Se calcula dividiendo la covarianza por el producto de las desviaciones estándar de X e Y: $\rho_{X, Y} = \text{Cov}(X, Y) / (\sigma_X \sigma_Y)$. Este coeficiente siempre varía entre -1 y $+1$. Un valor de $+1$ indica una relación lineal positiva perfecta, -1 indica una relación lineal negativa perfecta, y 0 indica la ausencia de relación lineal. El coeficiente de correlación es una medida adimensional y universalmente interpretable de la fuerza de la asociación lineal.

Es fundamental recordar que la covarianza y la correlación solo miden la **asociación lineal**. Si dos variables son independientes, su covarianza es cero. Sin embargo, la inversa no es necesariamente cierta: una covarianza de cero no implica independencia, ya que puede existir una fuerte relación no lineal (por ejemplo, una relación cuadrática) que la correlación de Pearson no logra capturar. Por lo tanto, para determinar la independencia completa, se debe verificar la condición de factorización de la función conjunta, no solo la anulación de la covarianza.

6. Aplicaciones Prácticas y Modelado

La distribución de probabilidad bivariada es una herramienta indispensable en prácticamente todas las disciplinas cuantitativas, ya que permite modelar y predecir el comportamiento conjunto

de fenómenos interdependientes.

En el ámbito de las **Finanzas**, las distribuciones bivariadas son cruciales para la gestión de riesgos y la optimización de carteras. Para evaluar el riesgo de una cartera compuesta por dos activos, es necesario conocer la distribución conjunta de sus rendimientos. La covarianza entre los rendimientos de dos activos determina el grado de diversificación: si los rendimientos están fuertemente correlacionados positivamente, la diversificación es mínima; si están correlacionados negativamente, se reduce significativamente la variabilidad total de la cartera. Modelos avanzados a menudo utilizan distribuciones elípticas o **cóputas** para modelar estructuras de dependencia más complejas que la simple correlación lineal.

En **Ingeniería y Ciencias Ambientales**, las distribuciones bivariadas se utilizan para modelar la fiabilidad de sistemas y el riesgo de eventos extremos. Por ejemplo, en hidrología, es vital modelar la distribución conjunta de la intensidad de la lluvia y la duración de la tormenta, ya que la probabilidad de una inundación catastrófica depende de la combinación de ambas. En la ingeniería de fiabilidad, se modela el tiempo de fallo conjunto de dos componentes interconectados para predecir la vida útil del sistema.

En **Medicina y Epidemiología**, estas distribuciones ayudan a entender la relación entre factores de riesgo y resultados de salud. Se puede modelar la probabilidad conjunta de tener una dieta alta en grasas (X) y desarrollar una enfermedad cardiovascular (Y). La distribución condicional $P(Y|X)$ es la base para calcular el riesgo relativo y otros indicadores epidemiológicos esenciales. De manera similar, en la **Econometría**, los modelos de regresión múltiple se basan implícitamente en el análisis de las distribuciones condicionales de la variable dependiente dados los valores de las variables explicativas.

7. Desafíos y Extensiones: Cóputas

Aunque la distribución bivariada proporciona un marco robusto, presenta desafíos, especialmente cuando la estructura de dependencia entre X e Y no es lineal o cuando las distribuciones marginales no son normales. La distribución Normal Bivariada, si bien es matemáticamente conveniente, a menudo falla al modelar fenómenos reales que exhiben **dependencia de cola**, es decir, una fuerte correlación durante eventos extremos (colas de la distribución).

Para abordar estas limitaciones, la teoría de las **cóputas** ha emergido como una extensión poderosa. Una cóputa es una función que une o "acopla" las distribuciones marginales univariadas a su distribución conjunta. El teorema de Sklar establece que cualquier distribución de probabilidad conjunta puede ser descompuesta en sus distribuciones marginales y una cóputa que captura toda la estructura de dependencia. Esta separación es ventajosa porque permite a los modeladores elegir libremente las distribuciones marginales que mejor se ajusten a los datos individuales (por ejemplo, una distribución Weibull para X y una Gamma para Y) y luego

seleccionar una cópula (como la cópula de Clayton o Gumbel) que modele la dependencia observada, incluyendo la dependencia de cola.

El uso de cópulas, especialmente crucial en la gestión avanzada de riesgos y seguros, ha permitido crear modelos bivariados mucho más flexibles y realistas que los modelos paramétricos tradicionales. Sin embargo, este enfoque también introduce la complejidad de la selección y estimación de la cópula adecuada, un área activa de investigación estadística.

Lecturas Adicionales

[Distribución de probabilidad conjunta](#) (Wikipedia)

[Variable Aleatoria](#) (Wikipedia)

[Covarianza](#) (Wikipedia)

[Bivariate Normal Distribution](#) (StatLect)

[Cópula \(Estadística\)](#) (Wikipedia)

ARABPSYCHOLOGY.COM