

# Variables Aleatorias y Funciones de Densidad

Dr. Delfino Vargas Chanes

Facultad de Economía  
Universidad Nacional Autónoma de México

13 de marzo de 2024



# Índice

1. Funciones
2. Variable Aleatoria
3. Binomial
4. Esperanza
5. Normal



# Funciones

## Definición 1.1

Sean  $X, Y$  conjuntos cualesquiera. Una función  $f$  de  $X$  a  $Y$  es un objeto que,  $\forall x \in X$  se le asigna un **único** elemento  $y \in Y$ . Denotamos estos objetos como  $f : X \rightarrow Y$ . Llamamos a  $X$  el dominio de  $f$ , mientras que  $Y$  es el codominio de  $f$ .

- Decimos que una función  $f : X \rightarrow Y$  está **bien definida** si cumple con lo siguiente
  - Totalidad:  $\forall x \in X \exists y$  tal que  $f(x) = y$
  - Existencia:  $\forall x \in X \Rightarrow f(x) \in Y$
  - Unicidad:  $\forall x \in X$  solo hay una  $y \in Y$  tal que  $f(x) = y$
- Ejemplos de funciones
  - $f : \mathbb{Z} \rightarrow \mathbb{Z}$  definida por  $f(x) = 2x$
  - $F : \mathbb{R}^3 \rightarrow \mathbb{R}$  definida como  $F(K, N) = AK^\alpha L^{1-\alpha}$
  - $\phi : \mathbb{R} \rightarrow \mathbb{R}$  definida como  $\phi(x) = x^2 + x + 3$



# Propiedades

## Definición 1.2

Sean  $X, Y$  conjuntos cualesquiera y  $f : X \rightarrow Y$  una función. Decimos que es inyectiva si  $\forall x, y \in X$  si  $f(x) = f(y) \Rightarrow x = y$

## Definición 1.3

Sean  $X, Y$  conjuntos cualesquiera y  $f : X \rightarrow Y$  una función. Decimos que es suprayectiva si  $\forall y \in Y \exists x \in X$  tal que  $f(x) = y$

## Definición 1.4

Sean  $X, Y$  conjuntos cualesquiera y  $f : X \rightarrow Y$  una función. Decimos que es biyectiva si es suprayectiva e inyectiva.



# Variable Aleatoria

## Definición 2.1

Dado un experimento en un espacio muestral  $\Omega$ , una *variable aleatoria*  $X$  es una función que va de  $\Omega$  a  $\mathbb{R}$ , es decir

$$X : \Omega \rightarrow \mathbb{R}$$

- Estaremos refiriéndonos a las variables aleatorias como VA.
- Una variable aleatoria  $X$  es una función que asocia un valor numérico  $X(s)$  a cada resultado posible de un experimento aleatorio  $s \in \Omega$ .
- En un espacio muestral  $\Omega : \{AA, AS, SA, SS\}$ , las siguientes son VA:
  - El número de Águilas es una VA con valores 0, 1, 2.
  - $Y$  es una VA que es 1 si el primer lanzamiento es Águila y 0 si no.
  - En ese caso se le asigna a los eventos  $AA$  y  $AS$  el valor 1.



# Variable Aleatoria

- A continuación, más ejemplos de VA.
- Escojamos una persona al azar del salón, y sea el color de sus ojos  $X$ .
- El número de embarazos después del uso correcto de anticonceptivos.
- La cantidad de bacteria en un estudio de crecimiento bacterial.
- El tiempo en el que Tadej Pogačar completará el Tour de France 2024.
- El valor del IPC México (MXX) al cierre del mercado mañana.
- La fuente de la aleatoriedad de la variable es el experimento mismo, en el que de un evento  $s \in \Omega$  se escoge mediante una función de probabilidad  $P$ . Definiremos estas mas adelante.
- Antes del experimento, no sabemos cual es la VA, solo podemos calcular su probabilidad. Después del experimento, si la VA es  $X$  entonces su valor número para un experimento  $s$  es  $X(s)$ .



# VA Discreta

## Definición 2.2

Decimos que una variable aleatoria  $X$  es discreta si hay una lista finita de valores  $a_1, a_2, \dots, a_n$  o una lista infinita numerable  $a_1, a_2, \dots$  tales que

$$\sum_i P(X = a_i \text{ para alguna } i = 1, 2, \dots) = 1$$

Es decir, los valores constituyen un conjunto numerable, sea finito o infinito.



# Función de Masa de Probabilidad

- Hemos afirmado que una variable aleatoria discreta puede tomar un número infinito de valores.
- En la práctica podemos usar los conceptos de probabilidad para poder establecer las reglas de asignación de los valores que toman las VA.
- Para ello adoptamos el concepto de función de distribución de probabilidad.





# Función de Masa de Probabilidad

## Definición 2.3

La función de masa de probabilidad (PMF) de una VA discreta es la función  $p_X$  dada por  $p_X(X) = P(X = x)$ . Formalmente:

$$p(X = x) = P(\{s \in \Omega \mid X(s) = x\}) = P(X^{-1}(x))$$

- Al escribir  $P(X = x)$  estamos utilizando  $X = x$  para denotar un evento, que consiste en todos los resultados  $s \in \Omega$  para los cuales la VA  $X$  asigna el valor  $x \in \mathbb{R}$ .



## Teorema 2.1

Sea  $X$  una VA discreta. Su PMF  $p_X$  cumple las siguientes propiedades:

1.  $\forall j \in 1, \dots \Rightarrow p_X(x_j) > 0$ . Las VA  $X$  con probabilidad 0 no se enlistan.

2. 
$$\sum_{i=1}^{\infty} p_X(x_i) = 1$$

## Demostración.

La primera es trivial por la no negatividad de la probabilidad. Para la segunda, se tiene que:

$$\sum_{i=1}^{\infty} P(X = x_i) = P\left(\bigcup_{i=1}^{\infty} \{X = x_i\}\right) = P(X = x_1 \text{ o } X = x_2 \text{ o } \dots) = 1$$



# Ejemplos

- La implicación de estas propiedades con un ejemplo de tres lanzamientos de una moneda, con  $X$  la VA observar si cae águila.
- Estos valores se pueden reordenar en una tabla más sencilla, ya que de ocho lanzamientos uno no cae águila.
- Por ejemplo se tiene  $P(X = 0) = \frac{1}{8}$  o  $P(X = 2) = \frac{3}{8}$

Valor de $X = x$	$p_X(x)$
0	$\frac{1}{8}$
1	$\frac{1}{8}$
2	$\frac{3}{8}$
3	$\frac{1}{8}$
Total	1



# Introducción

- En esta parte se revisan las distribuciones básicas donde la variable de respuesta es binaria (dos categorías).
- Un modelo de probabilidad es una forma que modela la distribución de probabilidad y el comportamiento de una variable aleatoria. Las probabilidades se expresan en términos de cantidades relevantes llamadas parámetros.
- En esta parte también introducimos el concepto de pruebas de hipótesis. Este concepto será crucial para el resto del curso.



# Éxito y Fracaso

- A continuación, ejemplos de donde los elementos de la población presentan una dicotomía (respuesta binaria):
- Inspección de varios artículos que provienen de una línea de producción y se cuenta el número de artículos defectuosos.
- Levantar una encuesta de votantes y observar cuántos de ellos votan a favor de una propuesta.
- Analizar los especímenes de sangre tomados de ratas y contar cuántas de ellas son portadoras de cierta enfermedad.
- Examinar historias de casos de un número de nacimientos y contar cuantos fueron inducidos por cesárea



# Distribución Bernoulli

## Definición 3.1

Se dice que una VA  $X$  tiene distribución Bernoulli con parámetro  $p$ , si  $P(X = 1) = p$  y  $P(X = 0) = 1 - p$ , donde  $p \in (0, 1)$ . Se escribe como  $X \sim \text{Bern}(p)$ . El símbolo  $\sim$  se lee "se distribuye como"

- Cualquier VA con valores posibles 0 y 1, tiene una distribución  $\text{Bern}(p)$ , con un parámetro  $p$  asociado.
- Este número  $p$  determina que distribución en particular se tiene.
- No solo hay una distribución Bernoulli, pero toda una familia.
- Cualquier evento en un espacio muestral cualquiera tiene una VA asociada a el, igual a 1 si sucede y a 0 si no sucede.



# Variable Indicatriz

## Definición 3.2

La VA indicatriz de un evento  $A$  es la VA que es igual a 1 si ocurre, y a 0 si no ocurre. Denotamos la VA indicatriz de  $A$  como  $I_A$ . Notemos que,  $I_A \sim \text{Bern}(p)$  con  $p = P(A)$ .



# Ensayos Bernoulli

## Definición 3.3

Un experimento que resulta o en un *éxito* o un *fracaso*, pero no ambas, se llama un ensayo Bernoulli. Una VA Bernoulli es en realidad un el indicador del éxito en un ensayo Bernoulli, es 1 si hay éxito, y 0 si hay fracaso. Denotamos entonces al parámetro  $p$  como la probabilidad de éxito de una distribución  $\text{Bern}(p)$ .





# Distribución Binomial

## Definición 3.4

Suponga que se realizan  $n$  ensayos Bernoulli independientes, cada uno con la misma probabilidad  $p$  asociada. Sea  $X$  una VA que denota el número de éxitos. La distribución de  $X$  se llama distribución binomial, de parámetros  $n$  y  $p$ . Se denota como  $X \sim \text{Bin}(n, p)$ , donde  $n \in \mathbb{Z}^+$  y  $p \in (0, 1)$ .



# Distribución Binomial

## Teorema 3.1

Si  $X \sim \text{Bin}(n, p) \Rightarrow$  la PDF de  $X$  es

$$p_X = P(X = x) = \binom{n}{k} p^k (1 - p)^{n-k}$$

para  $k = 0, 1, \dots, n$ , con  $P(X = k) = 0$  de lo contrario.



# Demostración de la PDF

## Demostración.

Cuando uno ha obtenido  $k$  éxitos en  $n$  ensayos, también se obtienen  $(n - k)$  fracasos. La probabilidad de  $k$  éxitos y  $(n - k)$  fracasos cuando el orden importa es

$$p^k(1 - p)^{n-k}$$

Cuando el orden no importa, también podemos combinar  $k$  éxitos y  $(n - k)$  fracasos. Este número es el número de posibilidad de encontrar  $k$  objetos de  $n$  objetos, o sea, el coeficiente binomial

$$\binom{n}{k}$$

Debemos multiplicar estas dos expresiones para obtener la probabilidad de  $k$  éxitos y  $(n - k)$  fracasos. Pero esto es la PDF. □

# PDF Binomial

- Esta PDF es válida porque cumple con las propiedades mencionadas.
- Es evidente que es no negativa.
- En cuanto a que su suma sea igual a 1, veamos que

$$1 = 1^n = (p + 1 - p)^n = \sum_{k=0}^n \binom{n}{k} p^k (1 - p)^{n-k}$$

- Esto por el teorema del binomio, que postula

$$(x + y)^n = \sum_{k=0}^n \binom{n}{k} y^k \cdot x^{n-k}$$



# Teorema de Binomial

## Teorema 3.2

Sea  $X \sim \text{Bin}(n, p)$  y definamos a  $q = 1 - p \Rightarrow n - X \sim \text{Bin}(n, q)$

### Demostración.

Veamos que  $n - X$  tiene la PDF de la binomial. Sea  $Y = n - x$

$$P(Y = k) = P(X = n - k) = \binom{n}{n - k} p^{n-k} (q)^k = \binom{n}{k} q^k (p)^{n-k}$$



# Ejemplos Binomial I

- De acuerdo a las leyes de Mendell si tenemos que si hay solo plantas rojas y blancas la heredabilidad es del 25 % para las flores rojas.
- Suponga que se cruzan 5 pares de flores rojas y blancas. Entonces ¿Cuál es la probabilidad de lo siguiente?
  - ¿No haya plantas rojas?
  - ¿Haya 4 o más plantas rojas?
- Dado que los ensayos ocurren con diferentes plantas (orígenes diferentes), entonces se cumple la independencia.
- Sea  $X$  la variable aleatoria que denota el evento de las plantas rojas de entre las 5 posibles.
- Si el evento  $E$  se define como obtener plantas rojas. Entonces la teoría Mendeliana especifica que  $P(E) = .25$  y tiene una distribución  $X \sim \text{Bin}(n = 5, p = .25)$ .



# Ejemplos Binomial I

- Entonces se requiere calcular

$$P(X = 0) = \binom{5}{0} p^0 (1 - p)^{5-0} = 0.75^5 = 0.237$$

$$P(X \geq 4) = \binom{5}{4} p^4 (1 - p)^{5-4} + \binom{5}{5} p^5 (1 - p)^0$$

- Realizando los cálculos se tiene que

$$= 0.015 + 0.001 = 0.016$$



## Ejemplos Binomial II

- Tiremos un dado. Sea  $X$  el número de veces que aparece el número 6 en los primeros 10 lanzamientos, y  $Y$  el número de lanzamientos necesarios para obtener un 3.
- En efecto,  $X \sim \text{Bin}(10, \frac{1}{6})$ . Escribamos la función de masa de probabilidad de  $X$ , para algún  $i = 1, \dots, 10$

$$P(X = k) = \binom{10}{k} \left(\frac{1}{6}\right)^k 1 - \left(\frac{1}{6}\right)^{10-k}$$

- Veamos este ejemplo de Wikipedia
- Suponga una moneda con maña. La traza es que la probabilidad que salga sol es de 0.3. La probabilidad de obtener 4 soles en 6 lances es

$$P(X = 4) = \binom{6}{4} 0.3^4 (1 - 0.3)^{6-4} = 0.059535$$





# Función de distribución acumulada

## Definición 3.5

Decimos que la función de distribución acumulada (CDF) de una VA llamada  $X$  cualquiera es la función  $F_X$  dada por  $F_X(x) = P(X \leq x)$

## Teorema 3.3

Si  $X \sim \text{Bin}(n, p) \Rightarrow$  la CDF de  $X$  es

$$F_X = P(X \leq x) = \sum_{i=0}^{\lfloor k \rfloor} \binom{n}{i} p^i (1-p)^{n-i}$$



# CDF

- Las CDF deben de cumplir con las siguientes propiedades.
- Si  $x \leq y \Rightarrow F_X(x) \leq F_X(y)$
- $\forall a \Rightarrow F_X(a) = \lim_{x \rightarrow a^+} F_X(x)$ , la función es continua por la derecha.
- $\lim_{x \rightarrow -\infty} F_X(x) = 0$  y  $\lim_{x \rightarrow \infty} F_X(x) = 1$



# Binomial en R

- Existen tres funciones asociadas a la Binomial en RStudio.
- `dbinom` es la PDF Binomial. Toma en cuenta el valor de  $x$ , y los parámetros  $n$ , llamado `size`, y  $p$ , llamado `prob`.
- Por ejemplo, recordemos nuestro ejemplo de la moneda con maña

$$P(X = 4) = \binom{6}{4} 0.3^4 (1 - 0.3)^{6-4} = 0.059535$$

En este caso `dbinom(x=4, size=6, prob=0.3)`.

- `pbinom` es la CDF de la binomial.
- `rbinom` genera números que siguen una distribución binomial para los parámetros elegidos. En las tres son un valor, `size` y `prob`. Sin embargo, para esta, se tiene que es cuantas VA queremos generar.



# Cálculo de `dbinom`, `pbinom` y `rbinom` en R

```
dbinom(x=4, size=6, prob=0.3)  
[1] 0.059535
```

```
pbinom(30, 100, 0.3)  
[1] 0.5491236
```

```
#Codigo para la grafica empieza aqua
```

```
set.seed(10)  
rbinom(1, 100, 0.3)  
binomial_data <- rbinom(1000, 100, 0.3)  
binomial_data <- as.data.frame(binomial_data)  
names(binomial_data) <- c
```



# Cálculo de dbinom, pbinom y rbinom en R

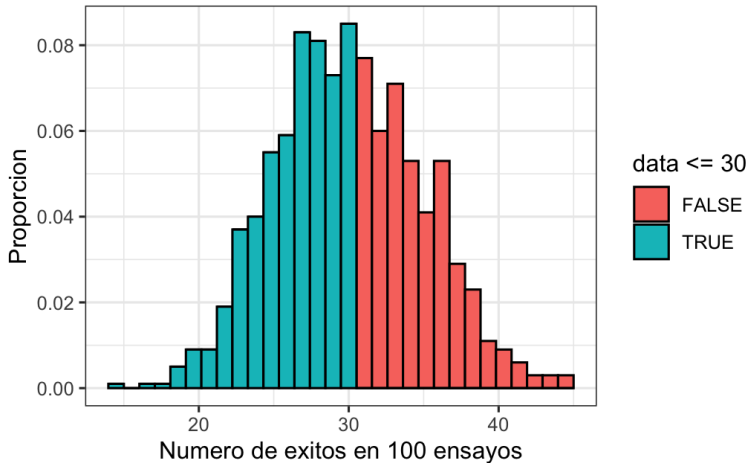
```
pbinom(30, 100, 0.3)

binomial_data %>% ggplot() +
  geom_histogram(aes(x = data,
                    y = stat(count / sum(count)),
                    fill = data <= 30),
                color = 'black') +
  theme_bw() +
  labs(x = 'Numero de exitos en 100 ensayos',
       y = 'Proporcion',
       title = '1000 muestras de Binom(100, 0.3)')
```



# Gráfica de pbinom

1000 muestras de Binom(100, 0.3)



# Funciones de VA

- Note que las funciones de VA también son VA aleatorias. e.g., para  $X$  una VA aleatoria cualquiera,  $X^2$ ,  $\sin(x)$ ,  $\log(X)$  también son VA.

## Definición 3.6

Para un experimento cualquiera  $s$  en un espacio muestral  $\Omega$  una VA  $X$  y una función  $g : \mathbb{R} \rightarrow \mathbb{R} \Rightarrow g(X)$  es la VA que mapea o transforma  $s$  a

$$g(X(s))$$

$$\forall s \in \Omega$$



# Independencia

## Definición 3.7

Decimos que dos VA  $X$  y  $Y$  son independientes si

$$P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y)$$

$$\forall x, y \in \mathbb{R}$$

## Definición 3.8

Decimos que  $n$  VA  $X_1, \dots, X_n$  son independientes si

$$P(X_1 \leq x_1, \dots, X_n \leq x_n) = P(X_1 \leq x_1) \dots P(X_n \leq x_n)$$

$$\forall x_1, \dots, x_n \in \mathbb{R}$$



# Valor Esperado

## Definición 4.1

El valor esperado de una VA discreta  $X$  cuyos valores posibles son  $x_1, x_2, \dots$  se define como

$$\mathbb{E}[X] = \sum_{i=1}^{\infty} x_i P(X = x_i)$$

- La definición de valor esperado es similar a la de la media ponderada.
- En este caso, los *pesos* son las probabilidades.
- Es decir, el valor esperado de una VA  $X$  es una media ponderada de los valores que puede tomar  $X$ , ponderado por sus probabilidades.



# Ejemplos

- Sea  $X$  una VA con  $P(X = 1) = 0.2$ ,  $P(X = 2) = 0.3$ , y  $P(X = 3) = 0.5$ . ¿Cuál es  $\mathbb{E}[X]$ ?
- Utilicemos la definición anterior:

$$\sum_{i=1}^3 x_i P(X = x_i) = 1 \cdot 0.2 + 2 \cdot 0.3 + 3 \cdot 0.5 = 2.3$$

- Sea  $X$  el resultado de lanzar un dado sin maña. En este caso las  $x_i$  toman el valor de 1, 2, 3, 4, 5, 6, las caras del dado.
- Todas las  $x_i$  tienen la misma  $P(X = x_i) = \frac{1}{6}$ . ¿Cuál es  $\mathbb{E}[X]$ ?

$$\begin{aligned} \sum_{i=1}^6 x_i P(X = x_i) &= 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + 3 \cdot \frac{1}{6} + 4 \cdot \frac{1}{6} + 5 \cdot \frac{1}{6} + 6 \cdot \frac{1}{6} \\ &= \frac{1}{6}(1 + 2 + 3 + 4 + 5 + 6) = 3.5 \end{aligned}$$



# Linealidad de $\mathbb{E}$

## Teorema 4.1

Sea  $X$  una VA cualquiera y  $\lambda \in \mathbb{R} \Rightarrow$

$$\mathbb{E}[X + Y] = \mathbb{E}[X] + \mathbb{E}[Y]$$

y además

$$\mathbb{E}[\lambda \cdot X] = \lambda \cdot \mathbb{E}[X]$$



# Valor Esperado de la Binomial

## Teorema 4.2

Sea  $X \sim \text{Bin}(n, p)$  una VA. Entonces,  $\mathbb{E}[X] = np$



## Demostración.

$$\begin{aligned}\mathbb{E}[X] &= \sum_{k=1}^n k \binom{n}{k} p^k q^{n-k} \\ &= \sum_{k=1}^n n \binom{n-1}{k-1} p^k q^{n-k} \\ &= np \sum_{k=1}^n \binom{n-1}{k-1} p^{k-1} q^{(n-1)-(k-1)} \\ &= np \cdot (p+q)^n = 1^n \cdot np = np\end{aligned}$$



# Varianza y Desviación Estándar

## Definición 4.2

Sea  $\mu = \mathbb{E}[X]$  Definimos a la varianza de una VA  $X$  como

$$\text{Var}[X] = \mathbb{E}[X - \mu]^2$$

La raíz cuadrada de la varianza se llama desviación estandar

$$\text{SD}[X] = \sqrt{\text{Var}[X]}$$



# Varianza

## Teorema 4.3

Para cualquier VA  $X$

$$\text{Var}[X] = \mathbb{E}[X^2] - \mu^2$$

## Demostración.

$$\begin{aligned}\text{Var}[X] &= \mathbb{E}[X - \mu]^2 = \mathbb{E}[X^2 - 2\mu X + \mu^2] \\ &= \mathbb{E}[X^2] - 2\mu\mathbb{E}[X] + \mu^2 = \mathbb{E}[X^2] - 2\mu^2 + \mu^2 \\ &= \mathbb{E}[X^2] - \mu^2\end{aligned}$$



# Varianza

- La varianza cumple las siguientes propiedades:
- $\text{Var}[X + \lambda] = \text{Var}[X]$
- $\text{Var}[\lambda \cdot X] = \lambda^2 \cdot \text{Var}[X]$
- Si  $X$  y  $Y$  son independientes,  $\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y]$
- Las únicas VA con varianza cero son las constantes.





# Variables Aleatorias Continuas

- Hasta ahora hemos estado trabajando con VA discretas, es decir, que son numerables y podemos enlistar.
- En esta parte, estaremos trabajando con variables aleatorias continuas.
- Estas VA, pueden tomar cualquier valor en  $\mathbb{R}$  en un intervalo.
- Antes de definir las, necesitamos la intuición de lo que es una integral.



# Integral

- Al no ser un curso de cálculo, no daremos una definición formal.
- Sea  $f : [a, b] \rightarrow \mathbb{R}$ . Detrás de la integral, está la motivación de aproximar el área bajo la curva de la función  $y = f(x)$ , donde  $a \leq x \leq b$ .
- Tomamos  $N$  particiones del eje  $x$  en un intervalo de  $a$  a  $b$  dividiendolo entre ese número.  $\Delta x = \frac{x_m}{N}$
- Estas particiones son la *base* del rectángulo. Para la altura, consideramos el valor de la función  $f$ , lo que se proyecta en el eje de las  $y$ .

$$\text{Área} \approx \sum_{i=1}^N f_i \Delta x$$

- Mientras más grande sea  $N$ , más rectángulos tenemos, y más se aproxima al valor del área bajo la curva.



# Integral

- Notemos que cuando  $N \rightarrow \infty$ , la fracción  $\Delta = \frac{x_m}{N} \rightarrow 0$
- La integral es cuando tomamos el límite cuando la base de los rectángulos, es decir  $\Delta x \rightarrow 0$

$$\text{Área} = \int_a^b f(x) dx = \lim_{\Delta x \rightarrow 0} \sum_{i=1}^N f_i \Delta x$$

- Se *calcula* el área entre  $a$  y  $b$ , donde  $dx$  es el diferencial de  $x$ .
- Presentamos una animación para facilitar la intuición.





# VA continua

## Definición 5.1

Decimos que la función de distribución acumulada (CDF) de una VA llamada  $X$  cualquiera es la función  $F_X$  dada por  $F_X(x) = P(X \leq x)$

## Definición 5.2

Decimos que una VA  $X$  es continua si su CDF es diferenciable.



# VA Continua

## Definición 5.3

Sea  $F_X(x)$  la CDF de una VA continua  $X$ . Entonces, denotamos a  $f(x)$  como

$$f(x) = \frac{dF(x)}{dx} = F'(x)$$

y le llamamos a  $f(x)$  la PDF de la VA  $X$ .

- Notemos que podemos escribir a la CDF como

$$F_X(x) = \int_{-\infty}^x f(t)dt$$



# VA Continua

## Definición 5.4

Si una VA continua  $X$  tiene una PDF  $f(x)$ , y se tiene que  $a < b$ , entonces, la probabilidad de que  $X$  caiga en el intervalo  $[a, b]$  es

$$P(a \leq x \leq b) = \int_a^b f(x) dx$$



# Propiedades de la PDF

## Teorema 5.1

Para que una PDF sea válida debe de cumplir lo siguiente:

$$f(x) \geq 0$$

No negativa, y se integra a 1.

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

Notemos que son las mismas que para una VA discreta, nada más que cambiamos la suma por la integral.





# Valor Esperado de VA Continuas

## Definición 5.5

El valor esperado de una variable aleatoria continua con PDF  $f$  es

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} x \cdot f(x) dx$$

Como nota, la varianza en VA continuas se computa de la misma forma que en la parte anterior.



# Distribución Normal

## Definición 5.6

Decimos que una VA  $X$  tiene distribución normal con media  $\mu$  y varianza  $\sigma^2$  (es decir, de parámetros  $\mu$  y  $\sigma$ )

$$X \sim \mathcal{N}(\mu, \sigma^2)$$

si y solo si su PDF es la siguiente

$$f(x) = \mathcal{N}(x; \mu, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} \cdot \exp\left[-\frac{1}{2}\left(\frac{x - \mu}{\sigma}\right)^2\right]$$

donde  $\mu \in \mathbb{R}$  y  $\sigma^2 > 0$



# Distribución Normal

Demostración.

Veamos que integra a 1 (Pendiente)



# Distribución Normal

## Teorema 5.2

Si  $X$  es una VA continua con distribución normal, entonces

$$\mathbb{E}[X] = \mu \quad \text{y} \quad \text{Var}[X] = \sigma^2$$

La demostración de este teorema se realizará más adelante.



# Distribución Normal Estandar

## Definición 5.7

Decimos que una VA  $X$  tiene distribución normal estandarizada si sigue una distribución normal con media 0 y desviación estándar 1.

$$X \sim \mathcal{N}(0, 1)$$

es decir, su PDF es

$$\varphi(x) = \mathcal{N}(x; 0, 1) = \frac{1}{\sqrt{2\pi}} \cdot \exp\left[-\frac{x^2}{2}\right]$$

La CDF se denota como

$$\Phi(x) = \int_{-\infty}^x \varphi(t) dt$$

# La variable estandarizada

- Si  $X$  es una variable aleatoria tal que  $X \sim \mathcal{N}(\mu, \sigma^2)$ , entonces la variable aleatoria  $Z$  se llama variable aleatoria estandarizada

$$Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$$

- La probabilidad en el intervalo  $(a, b)$  es el área bajo la curva.
- $P[a < X < b]$  se obtiene evaluando la diferencia entre las dos áreas. Área a la izquierda de  $b$  menos el área a la izquierda de  $a$ .
- $P[b < X]$  es el área a la izquierda de  $b$ . Veamos ejemplos.



# Comandos de R


- `dnorm(x, mean = 0, sd = 1)` calcula  $P(X = x)$ , para una normal estandarizada.
- `pnorm(q, mean = 0, sd = 1, lower.tail = TRUE)` calcula  $P(X \leq x)$ , mientras que `lower.tail = FALSE` calcula  $P(X > x)$ .
- Supongamos una VA  $X \sim \mathcal{N}(0, 1)$ , calculemos la probabilidad de que  $X$ , se utiliza para leer
- Utilizamos el comando `pnorm(-1, 0, 1) = 0.1586553`
- Podemos hacerlo para un intervalo, calculemos  $P(-2 \leq X \leq 1)$ , que se realizó con el código `pnorm(1, 0, 1) - pnorm(-2, 0, 1) = 0.8185946`
- Ahora para  $P(-2 \leq X \leq 2)$ , se tiene que `pnorm(2, 0, 1) - pnorm(-2, 0, 1) = 0.9544997`.



# Gráfica en R

La distribución normal  $N(0, 1)$

$P(X \geq -1)$






# Gráfica en R

La distriución normal  $N(0, 1)$


$P(-2 \leq X \leq 2)$



# Gráfica en R

La distribución normal  $N(0, 1)$

$P(-2 \leq X \leq 1)$



# Código en R

```
data.frame(x = c(-3.5, 3.5)) %>% ggplot(aes(x)) +
  stat_function(fun = dnorm,
               n = 1000,
               args = list(mean = 0,
                           sd = 1),
               size = 1) +
  geom_area(stat = 'function',
            fun = dnorm,
            fill = 'blue',
            xlim = c(-1, -3.5),
            alpha = 0.3) +
  theme_bw() +
  labs(y = 'Densidad f(x)',
       title = 'La distribución normal N(0, 1)',
       subtitle = 'P(X >= -1)') +
  scale_x_continuous(breaks = seq(-3, 3))
```



# Código en R

```
data.frame(x = c(-3.5, 3.5)) %>% ggplot(aes(x)) +
  stat_function(fun = dnorm,
               n = 1000,
               args = list(mean = 0,
                           sd = 1),
               size = 1) +
  geom_area(stat = 'function',
            fun = dnorm,
            fill = 'blue',
            xlim = c(-2, 2),
            alpha = 0.3) +
  theme_bw() +
  labs(y = 'Densidad f(x)',
       title = 'La distriucion normal N(0, 1)',
       subtitle = 'P(-2 <= X <= 2)') +
  scale_x_continuous(breaks = seq(-3, 3))
```



# Código en R

```
data.frame(x = c(-3.5, 3.5)) %>% ggplot(aes(x)) +
  stat_function(fun = dnorm,
               n = 1000,
               args = list(mean = 0,
                           sd = 1),
               size = 1) +
  geom_area(stat = 'function',
           fun = dnorm,
           fill = 'blue',
           xlim = c(-2, 1),
           alpha = 0.3) +
  theme_bw() +
  labs(y = 'Densidad f(x)',
       title = 'La distriucion normal N(0, 1)',
       subtitle = 'P(-2 <= X <= 1)') +
  scale_x_continuous(breaks = seq(-3, 3))
```



# Ejemplos

- Suponga que el IQ de unos monos tiene promedio 9.5 y desviación estándar de 1.7. Encontramos la proporción de monos con IQ menor a 5.

$$\text{pnorm}(5, 9.5, 1.7) = 0.004059761$$

- ¿Qué tal la proporción de monos con IQ menor a 9?

$$\text{pnorm}(9, 9.5, 1.7) = 0.384334$$

- Los frascos de jabón de AMLO suelen tener un promedio de volumen 90 ml, y desviación estandar, calcule la proporción del jabón entre 84.5 y 90.1

$$\text{pnorm}(90.5, 93, 5.3) - \text{pnorm}(84.5, 93, 5.3) = 0.2641892.$$



# Bibliografía

- Bernoulli, J. (1713). *Ars coniectandi*. Impensis Thurnisiorum, fratrum.
- Bhattacharyya, G. K., y Johnson, R. A. (1977). *Statistical concepts and methods*. Wiley.
- Bickel, P. J., y Doksum, K. A. (2015). *Mathematical statistics: basic ideas and selected topics, volumes i-ii package*. CRC Press.
- Fair, R. C. (1978). A theory of extramarital affairs. *Journal of political economy*, 86(1), 45–61.
- Groeneveld, R. A. (1998). A class of quantile measures for kurtosis. *The American Statistician*, 52(4), 325–329.
- Wackerly, D., Mendenhall, W., y Scheaffer, R. L. (2014). *Mathematical statistics with applications*. Cengage Learning.



¡Gracias por su atención!

