
COMPILANDO CONOCIMIENTO

Probabilidad y Estadística

MATEMÁTICAS ESTADÍSTICAS

Oscar Andrés Rosas Hernandez

Leticia Cañedo

Julio 2018

Índice general

0.1. ¿Qué es lo que estoy leyendo?	9
I Probabilidad Clásica	10
1. Introducción	11
1.1. Notación	12
1.1.1. Experimento ε	12
1.1.2. Espacio Muestral \mathcal{S}, Ω	12
1.1.3. Evento A	13
1.2. Probabilidad $P(A)$	14
1.2.1. Propiedades	15
1.3. Probabilidad Condicional	16
1.3.1. Propiedades	17
1.4. Eventos Independientes	18
1.4.1. Propiedades	18
1.4.2. Teorema de Bayes	19
2. Combinatoria	20
2.1. Ideas Clave	21
2.1.1. Orden vs Sin Orden	21
2.1.2. Reemplazar vs No Reemplazar	21
2.2. Permutación	22
2.2.1. Ejemplos	22
2.3. Combinación	23

2.3.1.	Combinaciones y Subconjuntos	23
2.3.2.	Ejemplos	23
2.3.3.	Propiedades Coeficientes Binomiales	24
II	Variables Aleatorias Discretas	25
3.	Variables Aleatorias Discretas	26
3.1.	Variables Aleatorias	27
3.1.1.	Variables Aleatorias Discretas	27
3.2.	Función Probabilidad f_X	28
3.2.1.	Definición	28
3.2.2.	Propiedades	28
3.2.3.	Ejemplos	29
3.3.	Función P. Acumulada F_X	30
3.3.1.	Definición	30
3.3.2.	Propiedades	30
3.3.3.	Función Fundamental	30
3.4.	Esperanza o Media	31
3.4.1.	Definición	31
3.4.2.	Propiedades	31
3.5.	Varianza	32
3.5.1.	Definición	32
3.5.2.	Desviación Estandar	32
3.5.3.	Propiedades	33
3.6.	Covarianza	35
3.6.1.	Definición	35
3.6.2.	Propiedades	35
3.7.	Momentos Centrales	36
3.7.1.	Propiedades	36
3.7.2.	Función Generadora de Momentos	37
3.7.3.	Propiedades	38

4. Distribuciones Famosas	39
4.1. Bernoulli	40
4.1.1. Definición	40
4.1.2. Función Probabilidad	41
4.1.3. Función P. Acumulada	41
4.1.4. Esperanza	42
4.1.5. Varianza	42
4.1.6. Función Generadora	43
4.2. Binomial	44
4.2.1. Definición	44
4.2.2. Función Probabilidad	45
4.2.3. Función P. Acumulada	45
4.2.4. Esperanza	45
4.2.5. Varianza	46
4.2.6. Función Generadora	46
4.2.7. Propiedades	47
4.3. Geométrica	48
4.3.1. Definición	48
4.3.2. Función Probabilidad	49
4.3.3. Función P. Acumulada	49
4.3.4. Esperanza	50
4.3.5. Varianza	51
4.3.6. Función Generadora	52
4.3.7. Propiedades	53
4.4. Hiper-Geométrica	54
4.4.1. Definición	54
4.4.2. Función Probabilidad	56
4.4.3. Función P. Acumulada	56
4.4.4. Esperanza	57
4.4.5. Varianza	57

4.4.6.	Función Generadora	58
4.4.7.	Relación con la Binomial	59
4.5.	Poisson	60
4.5.1.	Función Probabilidad	61
4.5.2.	Función P. Acumulada	61
4.5.3.	Función Generadora	62
4.5.4.	Esperanza	63
4.5.5.	Varianza	63
4.5.6.	Relación con la Binomial	64
4.5.7.	Propiedades	65
 III Variables Aleatorias Continuas		66
 5. Variables Aleatorias Continuas		67
5.1.	Variables Aleatorias	68
5.1.1.	Variables Aleatorias Continuas	68
5.2.	Función Probabilidad f_X	69
5.2.1.	Definición	69
5.2.2.	Probabilidad Puntual	69
5.3.	Función P. Acumulada F_X	70
5.3.1.	Definición	70
5.3.2.	Propiedades	70
5.4.	Esperanza	71
5.4.1.	Definición	71
5.5.	Varianza	71
5.5.1.	Definición	71
5.6.	Función Generadora de Momentos	71
5.6.1.	Definición	71
 6. Distribuciones Continuas Famosas		72
6.1.	Uniforme	73

6.1.1.	Definición	73
6.1.2.	Función Probabilidad	74
6.1.3.	Función P. Acumulada	74
6.1.4.	Esperanza	75
6.1.5.	Varianza	76
6.1.6.	Función Generadora	77
6.2.	Exponencial	78
6.2.1.	Definición	78
6.2.2.	Función Probabilidad	79
6.2.3.	Función P. Acumulada	79
6.2.4.	Función Generadora	80
6.2.5.	Esperanza	80
6.2.6.	Varianza	81
6.2.7.	Propiedades	82
6.3.	Gamma	83
6.3.1.	Función Gamma	83
6.3.2.	Definición	84
6.3.3.	Función Probabilidad	85
6.3.4.	Función Acumulada	85
6.3.5.	Generadora de Momentos	86
6.3.6.	Esperanza	87
6.3.7.	Varianza	87
6.3.8.	Propiedades	88
6.4.	Normal	89
6.4.1.	Definición	89
6.4.2.	Estandarización	89
6.4.3.	Función Probabilidad	90
6.4.4.	Generadora de Momentos	91
6.4.5.	Media	92
6.4.6.	Varianza	92

6.4.7. Propiedades	93
7. Probabilidad Hardcore	94
7.1. Teorema Central del Límite	95
7.1.1. Definición	95
7.2. Teorema Central de Chebyshue	95
7.2.1. Definición	95
IV Probabilidades Conjuntas	96
8. Variables A. Multidimensionales	97
8.1. Función de Probabilidad	98
8.1.1. Discreto	98
8.1.2. Continuo	98
8.2. Distribución Acumulada	99
8.2.1. Discreto	99
8.2.2. Continuo	99
8.3. Distribución Marginal	100
8.3.1. Discreto	100
8.3.2. Continuo	100
8.4. Distribución Condicional	101
8.4.1. Discreto	101
8.4.2. Continuo	101
8.5. Independencia de Variables	102
8.5.1. Propiedades	102
V Estimaciones	103
9. Estimadores Puntuales	104
9.1. Características	105
9.1.1. Inssegado	105

9.1.2. Varianza Mínima 105

9.1.3. Optimo 106

9.1.4. Optimo 106

9.2. Método de los Momentos 107

9.3. Método de Máxima Verosimilitud 107

VI CheatSheet - Formulario 108

10.CheatSheet - Formulario 109

10.1. Teoría de Conjuntos 110

10.2. Combinatoria 111

 10.2.1. Propiedades Coeficientes Binomiales 112

10.3. Probabilidad Básica 113

 10.3.1. Propiedades 113

10.4. Probabilidad Condicional 114

 10.4.1. Propiedades 114

10.5. Eventos Independientes 115

 10.5.1. Propiedades 115

 10.5.2. Teorema de Bayes 115

10.6. Variables Aleatorias Discretas 116

 10.6.1. Función Probabilidad f_X 116

 10.6.2. Función P. Acumulada F_X 117

 10.6.3. Esperanza o Media 118

 10.6.4. Varianza 119

 10.6.5. Covarianza 120

 10.6.6. Momentos Centrales 121

10.7. Distribuciones Discretas 123

 10.7.1. Bernoulli 123

 10.7.2. Binomial 124

 10.7.3. Geométrica 125

 10.7.4. HiperGeométrica 126

10.7.5. Poisson	128
10.8. Distribuciones Continuas	129
10.8.1. Uniforme	129
10.8.2. Exponencial	130
10.8.3. Gamma	131
10.8.4. Normal	132
10.9. Probabilidad Hardcore	133
10.9.1. Definición	133

0.1. ¿Qué es lo que estoy leyendo?

Hola... ¡Hey! Seguramente te estarás preguntando ¿Qué demonios estoy leyendo?

Bueno, este pequeño texto intenta darle solución a esa pregunta, la respuesta mas inmediata es que este texto (o compilado como nos gusta decirle) es una recopilación de teoremas, ideas y conceptos importantes que aprendí a lo largo del tiempo sobre este tema.

De manera regular estaremos actualizando estos textos con todo aquello nuevo que aprenda intentando profundizar en todos estos temas y cerrar posibles dudas en estas páginas, así que siempre mantente alerta de tener la última versión, esta siempre esta en CompilandoConocimiento.com

Este Compilado intenta ser lo más estricto posible, aunque somos humanos y es posible (e incluso probable) que cometamos pequeños errores de vez en cuando.

Estos textos están creados como una base con la que tu puedas leer rápidamente todo lo que hemos aprendido a lo largo del tiempo, aprender los conceptos más importantes y que usándo esto tu puedas profundizar más en la maravilla que es aprender más sobre este maravilloso mundo.

Este texto esta publicado bajo la GPL, por lo tanto es software libre y tu tienes el control total sobre el, puedes descargar este texto, puedes ver su código fuente, puedes modificarlo y puedes distribuir este texto y sus versiones modificadas, puedes acceder a todo lo que necesitas en el [Repositorio del Libro de Probabilidad](#).

Cualquier pregunta, comentario o si quieres contactar con nosotros no dudes en escribir al email del proyecto: CompilandoConocimiento@gmail.com

Espero que tomes estas páginas como un regalo, creado por seres imperfectos pero con muchos ánimos de hacer del mundo un lugar mejor, ahora si, abróchate los cinturones que esto acaba de empezar.

Compilar es Compartir

Parte I

Probabilidad Clásica

Capítulo 1

Introducción

1.1. Notación

Kolmogorov creo una axiomatización fuertemente basada en la teoría de la medida. En ella se habla de que un espacio de probabilidad tiene 3 elementos:

1. Un conjunto no vacío, Ω , llamado espacio muestral
2. \mathbb{F} una σ - algebra (digamos que es el conjunto de las posibles salidas, nota interesante que matemáticamente podemos decir que es un conjunto cerrado bajo operaciones conjuntivistas), es decir un subconjunto del conjunto potencia de Ω que cumple que:

$$a) \emptyset \in \mathbb{F}$$

$$b) \text{ Si } A \in \mathbb{F} \Rightarrow A^C \in \text{GenericField}$$

$$c) \text{ Si } A_1, A_2, \dots \in \mathbb{F} \Rightarrow \cup_{i=1}^{\infty} A_i \in \text{GenericField}$$

3. Una función $P : \mathbb{F} \rightarrow [0, 1]$ tal que:

$$a) P(\emptyset) = 0$$

$$b) \text{ Si } A_1, A_2, \dots \text{ son disjuntos entonces } P(\cup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} P(A_i)$$

$$c) P(\Omega) = 1$$

1.1.1. Experimento ε

Decimos que un experimento en probabilidad es cualquier proceso del cual se desconoce con determinación el resultado final.

Generalmente lo denotamos con mayúsculas.

1.1.2. Espacio Muestral S, Ω

Un espacio muestral asociado a un experimento es el conjunto de posibles resultados al momento de realizar el experimento.

Ejemplo:

Por ejemplo si ε_1 : Lanzar una moneda. Entonces tenemos que $S_1 = \{ \text{Cara}, \text{Cruz} \}$

Si ε_2 : Lanzar un dado. Entonces tenemos que $S_2 = \{ 1, 2, 3, 4, 5, 6 \}$

1.1.3. Evento A

Un evento es simplemente algún subconjunto del espacio muestral.

Ejemplo:

Por ejemplo si ε_1 : Lanzar una moneda. Entonces tenemos que un evento puede ser $A_1 = \{ Cara \}$

Si ε_2 : Lanzar un dado. Entonces tenemos que un evento puede ser $A_2 = \{ 1, 2, 4 \}$, $A_{2.1} = \{ 5 \}$

1.2. Probabilidad $P(A)$

Definimos la probabilidad de un evento A como:

$$P(A) = \frac{|A|}{|S|} \quad \text{Recuerda que } A \text{ es un evento y } S \text{ es espacio muestral}$$

Creo que es muy obvio por la manera en que definimos a la probabilidad de un evento es un número real entre 0 y 1.

Por lo tanto:

- **NO hay probabilidades negativas**
- **NO hay probabilidades mayores a uno**

Entonces podemos reducir el problema de encontrar la probabilidad de un evento simplemente a dos partes:

- Encontrar la cardinalidad de dicho evento
- Encontrar la cardinalidad del espacio muestral de un experimento

1.2.1. Propiedades

- $P(S) = 1$
- Si A_1, A_2, \dots, A_n son eventos mutuamente excluyentes entonces:

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i)$$

- $P(\emptyset) = 0$
- $P(A') = 1 - P(A)$

Demostración:

$$\begin{aligned} P(\Omega) &= P(A \cup A^C) && \text{como son disjuntos} \\ &= P(A) + P(A^C) && \text{por ser el universo} \\ 1 &= P(A) + P(A^C) \end{aligned}$$

- Si $A \subseteq B$ entonces $P(A) \leq P(B)$

Demostración:

$$\begin{aligned} P(B) &= P(A \cup (B - A)) && \text{y dado que } a \text{ y } B - A \text{ son disjuntos por definicion} \\ &= P(A) + P(B - A) && \text{Pero } P(B - A) \geq 0 \text{ entonces} \\ P(A) &\leq P(B) \end{aligned}$$

- La probabilidad de la unión de n eventos de puede escribir de manera general como:

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{i<j} P(A_i A_j) + \sum_{i<j<k} P(A_i A_j A_k) + \dots + (-1)^{n+1} P\left(\bigcap_{i=1}^n A_i\right)$$

- Por consecuencia del caso general tenemos que:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

- Por consecuencia del caso general tenemos que:

$$\begin{aligned} P(A \cup B \cup C) &= \\ &P(A) + P(B) + P(C) \\ &- (P(A \cap B) + P(A \cap C) + P(B \cap C)) \\ &+ P(A \cap B \cap C) \end{aligned}$$

- $P(A - B) = P(A) - P(A \cap B)$
- $P(A) = P(A \cap B) + P(A \cap B^C)$

1.3. Probabilidad Condicional

La probabilidad de que ocurra el Evento A conociendo que ya paso el Evento B se denota y define como:

$$P(A \mid B) := \frac{P(A \cap B)}{P(B)} = \frac{|A \cap B|}{|B|}$$

Nota que para que todo esto tenga sentido $P(B) \neq 0$

Podemos notar entonces que el evento B tiene muchas interpretaciones como:

- La condición que ya esta dada
- Evento que se sabe que ya ocurrió o que es seguro que ocurra
- Espacio Muestral Reducido

1.3.1. Propiedades

■ Conservamos Propiedades

La propiedad condicional cumple las propiedades que ya vimos de una propiedad de un evento cualquiera, pero ahora el espacio muestral que antes era S se ha reducido.

- $P(A \mid B) + P(A' \mid B) = 1$
- $P(A \cup B \mid C) = P(A \mid C) + P(B \mid C) - P(A \cap B \mid C)$

■ Definición Alternativa

Podemos redefinir a la probabilidad condicional como: $P(A \mid B) = \frac{|A \cap B|}{|B|}$

Demostración:

Esta es sencilla, muy sencilla:

$$\begin{aligned}
 P(A \mid B) &= \frac{P(A \cap B)}{P(B)} && \text{Por definición de Condicional} \\
 &= \frac{\frac{|A \cap B|}{|S|}}{\frac{|B|}{|S|}} && \text{Por definición de Probabilidad} \\
 &= \frac{|A \cap B|}{|B|} && \text{Magia}
 \end{aligned}$$

■ Regla de Multiplicación

Podemos escribir a $P(A \cap B)$ en términos de probabilidad condicional.

$$P(A \cap B) = P(A|B) P(B) = P(B|A) P(A)$$

Demostración:

Mira: Si $P(A|B) = \frac{P(A \cap B)}{P(B)}$ entonces $P(A|B)P(B) = P(A \cap B)$

$P(B|A) = \frac{P(B \cap A)}{P(A)}$ entonces $P(B|A)P(A) = P(A \cap B)$

1.4. Eventos Independientes

Dados 2 eventos que A, B son Independientes si y solo si $P(A) = P(A|B)$ y se escribe: $A \perp B$.

Es decir la ocurrencia de B no influye en nada a la ocurrencia de A , osea que pase o no pase B , a A le da igual.

1.4.1. Propiedades

- Si $A \perp B$ entonces $P(A \cap B) = P(A)P(B)$

Demostración:

Si $A \perp B$ entonces $B \perp A$ entonces $P(B) = P(B|A)$, por lo tanto $P(B) = \frac{P(B \cap A)}{P(A)}$

Y solo despejas

- Si $A \perp B$ entonces $A' \perp B'$

Demostración:

Esta es clave:

$$\begin{aligned} P(A' \cap B') &= P((A \cup B)') \\ &= 1 - [P(A) + P(B) + P(A \cap B)] \\ &= 1 - [P(A) + P(B) + P(A \cap B)] \\ &= (1 - P(A))(1 - P(B)) \\ &= P(A')P(B') \end{aligned}$$

- Si $A \perp B$ entonces $P(A \cap B) \neq 0$
- Si $P(A \cap B) = 0$ entonces A, B no son eventos independientes
- $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$

1.4.2. Teorema de Bayes

Considera un conjunto de eventos $\{A_1, \dots, A_n\}$ mutuamente excluyentes y tales que $\bigcup_{i=1}^n A_i = S$, es decir son particiones de S .

Entonces podemos escribir la probabilidad de un evento B donde $B \subset S$ como:

$$P(B) = \sum_{i=1}^n P(B|A_i) P(A_i)$$

Gracias a esto podemos decir que:

$$\begin{aligned} P(A_i|B) &= \frac{P(A_i \cap B)}{P(B)} \\ &= \frac{P(B|A_i) P(A_i)}{\sum_{i=1}^n P(A_i) P(B|A_i)} \end{aligned}$$

Capítulo 2

Combinatoria

2.1. Ideas Clave

2.1.1. Orden vs Sin Orden

En las muestras que están ordenadas entonces el orden de los elementos importa por ejemplo en los dígitos de un teléfono o en las letras de una palabra.

En las muestras que no están ordenadas el orden es irrelevante, por ejemplo en los elementos de un conjunto.

2.1.2. Reemplazar vs No Reemplazar

Las muestras con reemplazo entonces están permitidas, por ejemplo los números de la licencia.

Cuando la repetición no está permitida, por ejemplo en un conjunto de números de lotería

2.2. Permutación

Una permutación es un arreglo de objetos donde el orden es importante.

Entonces definimos a ${}_n P_r$ a la cantidad de muestras ordenadas de tamaño r sin remplazo de un conjunto de n objetos.

Entonces decimos que:

$${}_n P_r = \frac{n!}{(n-r)!} = (n)(n-1)(n-2)\dots(n-r+1)$$

2.2.1. Ejemplos

Ejemplo 1:

Considera $S = \{ a, b, c, d \}$, entonces podemos decir que:

- Hay 4 permutaciones distintas tomando solo una letra a la vez
- Hay 12 permutaciones distintas tomando solo dos letra a la vez
- Hay 24 permutaciones distintas tomando solo tres letra a la vez

Estas se pueden sacar facilmente con esta idea que creo que a todos nos enseñan, por ejemplo veamos como hacer el último punto:

$$\begin{array}{c} \underline{4} \quad \underline{3} \quad \underline{2} \\ \# \text{ De Posibles Elementos} \quad \# \text{ De Posibles Elementos} \quad \# \text{ De Posibles Elementos} \end{array} = (4)(3)(2) = 24$$

2.3. Combinación

Una permutación es un arreglo de objetos donde el orden NO es importante.

Entonces definimos a ${}_n C_r$ a la cantidad de muestras sin ordenadas de tamaño r sin remplazo de un conjunto de n objetos.

Entonces decimos que:

$$\binom{n}{r} = {}_n C_r = \frac{{}_n P_r}{r!} = \frac{n!}{r!(n-r)!} = \frac{(n)(n-1)(n-2)\dots(n-r+1)}{r!}$$

Esto tiene mucho sentido si lo ves desde otro angulo, pues en cuanto a las permutaciones tendremos $(n)(n-1)(n-2)\dots(n-r+1)$, pero resulta que muchas de esas permutaciones son basicamente la misma, solo cambiando el orden, así que si el orden ya no importa, es tan sencillo como dividir entre la cantidad de veces que podemos ordenar esas permutaciones de tamaño r

2.3.1. Combinaciones y Subconjuntos

Resulta ser que hay dos grande problemas clásicos de teoría de conjuntos que podemos resolver con combinaciones:

- El número de subconjuntos de cardinalidad r de un conjunto de n elementos

$$\binom{n}{r}$$

- Número de subconjuntos de un conjunto de n elementos:

$$\sum_{i=0}^n \binom{n}{i} = 2^n$$

2.3.2. Ejemplos

Ejemplo 1:

Cuantos equipos se puede formar que incluyan 2 físicos y 1 matemático si se sabe que hay 4 físicos y 3 matemáticos.

Ya que no nos importa el orden esto esta mas sencillo de lo que parece:

$$\binom{4}{2} \binom{3}{1} = \frac{4!}{2!(4-2)!} \frac{3!}{1!(3-1)!} = 18$$

2.3.3. Propiedades Coeficientes Binomiales

- Propiedades Simétricas

$$\binom{n}{k} = \binom{n}{n-k}$$

- Casos Especiales

$$\binom{n}{0} = \binom{n}{n} = 1 \quad \binom{n}{1} = \binom{n}{n-1} = n$$

- Teorema del Binomio

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

- Teorema del Binomio (Caso Especial)

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

- Propiedad bonita

$$\binom{n}{k} = \binom{n-1}{k-1} + \binom{n-1}{k}$$

Parte II

Variables Aleatorias Discretas

Capítulo 3

Variables Aleatorias Discretas

3.1. Variables Aleatorias

Una variable aleatoria es una función que asigna a cada elemento $E_i \in S$ en el espacio muestral a un número real $X(E_i) \in \mathbb{R}$, es decir, en español, lo que hace es que es una función que nos da información de una característica de cada elemento del espacio muestral.

Esta se denota con mayúsculas y no es un número, es una función. Para poner a un valor posible de una variable aleatoria lo denotamos con minúsculas.

3.1.1. Variables Aleatorias Discretas

Las variables aleatorias cuyo conjunto de valores posibles es finito o infinito contable entonces decimos que es una variable aleatoria discreta.

Ejemplo:

Por ejemplo considera que vas a lanzar 3 monedas, entonces tenemos que:

$$S = \{ ccc, ccx, cxc, xcc, xxc, xcx, cxx, xxx \}$$

Entonces podemos tener una variable aleatoria como:

Sea X = Número de caras en 3 lanzamientos.

Entonces podemos decir que:

$$X(ccc) = 3$$

$$X(ccx) = 2$$

$$X(cxc) = 2$$

$$X(xcc) = 2$$

$$X(xxc) = 1$$

$$X(xcx) = 1$$

$$X(cxx) = 1$$

$$X(xxx) = 0$$

Por lo tanto los vales posibles son 0, 1, 2, 3.

3.2. Función Probabilidad f_X

3.2.1. Definición

También se le conoce como función de probabilidad puntual. Es una función que toma todos los posibles valores una variable aleatoria y nos regresa un número real entre el 0 y el 1 dado por la probabilidad de el valor de la variable aleatoria sea x . Es decir:

$$f_X(x) = P(X = x)$$

3.2.2. Propiedades

Es una función de probabilidad, es decir tiene que cumplir que la suma de todos los posibles valores de la variable aleatoria den uno.

Más formalmente tenemos que la función probabilidad es aquella función que cumple que:

- $\forall a \in \mathbb{R} \quad 0 \leq f_X(a) \leq 1$
- $\{ x \mid f_X(x) \neq 0 \}$ es un conjunto finito o numerable
- $\sum_x f_X(x) = 1$

3.2.3. Ejemplos

Ejemplo:

Por ejemplo podemos definir la probabilidad del ejemplo pasado podemos definir la función

$$f_X(x) = \binom{3}{x} \left(\frac{1}{2}\right)^x \left(\frac{1}{2}\right)^{3-x} \text{ para } x \in \{0, 1, 2, 3\}$$

Entonces tenemos que:

- La probabilidad de que $X = 0$ (caigan 0 caras) es $\frac{1}{8}$
- La probabilidad de que $X = 1$ (caigan 1 caras) es $\frac{3}{8}$
- La probabilidad de que $X = 2$ (caigan 2 caras) es $\frac{3}{8}$
- La probabilidad de que $X = 3$ (caigan 3 caras) es $\frac{1}{8}$

3.3. Función P. Acumulada F_X

3.3.1. Definición

Describimos a la función de probabilidad acumulada como:

$$F_X(x) = \sum_{i \leq x} f_X(i)$$

3.3.2. Propiedades

- Una característica muy común es que:
 - $\lim_{x \rightarrow -\infty} F_X(x) = 0$
 - $\lim_{x \rightarrow \infty} F_X(x) = 1$
- Si $x_1 \leq x_2$ entonces $F_X(x_1) \leq F_X(x_2)$

3.3.3. Función Fundamental

Podemos ver a la acumulada como una función fundamental, tal que podemos escribir a todas las demás:

- $P(X = x) = F_X(x) - F_X(x - 1)$
- $P(X < x) = F_X(x - 1)$
- $P(X \leq x) = F_X(x)$
- $P(X > x) = 1 - F_X(x)$
- $P(X \geq x) = 1 - F_X(x - 1)$
- $P(a \leq X \leq b) = F_X(b) - F_X(a - 1)$
- $P(a < X \leq b) = F_X(b) - F_X(a)$
- $P(a \leq X < b) = F_X(b - 1) - F_X(a)$
- $P(a < X < b) = F_X(b - 1) - F_X(a - 1)$

3.4. Esperanza o Media

3.4.1. Definición

Decimos que el valor esperado, esperanza ó media de la variable X se define como:

$$\mu_X = E(X) = \sum_x x f_X(x) = \sum_x x P(X = x)$$

Representa un promedio ponderado de los valores posibles de la variable basado en sus probabilidades.

Es decir, si se repitiera el experimento muchísimas veces el promedio de los resultados se iría aproximando a la media.

3.4.2. Propiedades

- Si X puede tomar un número infinito de valores entonces la esperanza de X existe si y solo si $\sum_x |x| f_X(x) < \infty$

- Podemos dar una definición al evaluar la esperanza sobre una función:

$$E(g(x)) = \sum_x g(x) f_X(x)$$

- Es un Operador Lineal, es decir:

$$E(\alpha X + \beta Y) = \alpha E(X) + \beta E(Y)$$

- Si X, Y son independientes entonces:

$$E(XY) = E(X)E(Y)$$

- Si a es una constante, entonces:

$$E(a) = a$$

3.5. Varianza

3.5.1. Definición

Decimos que la varianza de la variable X con $f_X(x)$ se define como:

$$v(X) = E((X - \mu)^2)$$

Podemos decir por su misma definición que la varianza siempre es positiva.

Es decir, este valor nos indica que tan lejos están en promedio los valores de su misma media, es decir, que tan dispersa o concentrada está la distribución de los datos.

3.5.2. Desviación Estandar

Decimos que la desviación estandar de la variable X con $f_X(x)$ se define como:

$$\sigma(X) = \sqrt{v(X)}$$

Se usa generalmente por las unidades que tiene la varianza, nada más

3.5.3. Propiedades

- $v(X) = E(X^2) - (E(X))^2$

Demostración:

Esto esta demasiada sencillo:

$$\begin{aligned}
 v(X) &= E((X - \mu)^2) \\
 &= E(X^2 - 2x\mu + \mu^2) \\
 &= E(X^2) - E(2x\mu) + E(\mu^2) \\
 &= E(X^2) - 2\mu E(x) + E(\mu^2) \\
 &= E(X^2) - 2\mu^2 + \mu^2 \\
 &= E(X^2) - \mu^2
 \end{aligned}$$

- $V(a) = 0$

Demostración:

Sea $a = g(X)$, entonces su $\mu = a$, por lo tanto

$$\begin{aligned}
 V(a) &= E(a - a)^2) \\
 &= E(0)^2) \\
 &= 0
 \end{aligned}$$

- $v(aX) = a^2v(X)$

Demostración:

$$\begin{aligned}
 V(aX) &= E(aX^2) - E^2(aX) \\
 &= a^2E(X^2) - a^2E^2(X) \\
 &= a^2[E(X^2) - E^2(X)] \\
 &= a^2[v(X)]
 \end{aligned}$$

- $v(X + Y) = v(X) + v(Y) + 2Cov(X, Y)$

Demostración:

Esta esta larga:

$$\begin{aligned}
 v(X + Y) &= E(X + Y)^2 - (E(X + Y))^2 \\
 &= E(X) + E(Y) + 2E(XY) - (E(X + Y))^2 \\
 &= E(X) + E(Y) - (E(X) + E(Y))^2 + 2E(XY) \\
 &= E(X) + E(Y) - E^2(X) - E^2(Y) + 2E(XY) - 2E(X)E(Y) \\
 &= E(X) - E^2(X) + E(Y) - E^2(Y) + 2E(XY) - 2E(X)E(Y) \\
 &= v(x) + v(Y) + 2E(XY) - 2E(X)E(Y) \\
 &= v(x) + v(Y) + 2Cov(X, Y)
 \end{aligned}$$

- $v(aX + bY) = a^2v(X) + b^2v(Y) + 2ab \text{Cov}(X, Y)$
- $v(X - Y) = v(X) - v(Y) - 2\text{Cov}(X, Y)$

Demostración:

Es lo mismo, que la de arriba :v

- Si X y Y son independientes, entonces $v(X + Y) = v(X) + v(Y)$

Demostración:

Es lo mismo que la de arriba, solo recuerda que si X, Y son independientes entonces tenemos que $\text{Cov}(X, Y) = 0$

- En general si X_1, X_2, \dots, X_n son variables aleatorias, entonces tenemos que:

$$v\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n v(X_i) + 2\sum_{i < j}^n \text{Cov}(X_i, X_j)$$

Demostración:

Es inducción :v

3.6. Covarianza

3.6.1. Definición

Sea X, Y dos variables independientes, entonces definimos a la covarianza como:

$$\text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y))$$

Es una manera de medir la dispersión conjunta de ambas variables.

3.6.2. Propiedades

- $\text{Cov}(X, Y) = E(XY) - \mu_X\mu_Y$

Demostración:

Podemos demostrar esto, bien facil:

$$\begin{aligned} \text{Cov}(X, Y) &= E((X - \mu_X)(Y - \mu_Y)) \\ &= E(XY - X\mu_Y - \mu_X Y + \mu_X\mu_Y) \\ &= E(XY) - E(X\mu_Y) - E(\mu_X Y) + E(\mu_X\mu_Y) \\ &= E(XY) - \mu_Y E(X) - \mu_X E(Y) + E(\mu_X\mu_Y) \\ &= E(XY) - \mu_Y\mu_X - \mu_X\mu_Y + E(\mu_X\mu_Y) \\ &= E(XY) - \mu_Y\mu_X - \mu_X\mu_Y + \mu_X\mu_Y \\ &= E(XY) - \mu_Y\mu_X \end{aligned}$$

- La covarianza de 2 variables independientes es cero

Demostración:

Mira esto:

$$\begin{aligned} \text{Cov}(X, Y) &= E(XY) - \mu_Y\mu_X \\ &= E(X)E(Y) - \mu_Y\mu_X \\ &= 0 \end{aligned}$$

Si es que son independientes

Recuerda que $E(X) = \mu_X$

3.7. Momentos Centrales

Si X es una variable aleatoria tal que $E(X) = \mu_x$ entonces tenemos que:

- El k -ésimo momento central esta definida como:

$$\mu_k^c = E[(X - \mu)^k] = \sum_x (x - \mu)^k P(X = x) \quad (3.1)$$

- El k -ésimo momento alrededor del origen esta definida como:

$$\mu_k^0 = E(X^k) = \sum_x x^k P(X = x) \quad (3.2)$$

3.7.1. Propiedades

- Ya hemos trabajado con momentos, veamos algunos:

- **La Esperanza**

Esta se puede ver como el primer momento alrededor del origen

$$\mu_X = \mu_1^0$$

- **La Varianza**

Esta se puede ver como el primer momento alrededor central

$$v(X) = E[(X - \mu)^2] = \mu_2^c$$

O bien podemos verlo como $v(X) = E(X^2) - \mu^2$ donde $E(X^2)$ es un segundo momento alrededor del origen

3.7.2. Función Generadora de Momentos

La podemos definir como:

$$\Psi_X(t) = E(e^{tX}) = \sum_x e^{tx} P(X = x)$$

Solemos decir que la k -ésima derivada de la función generadora de momentos evaluada en $t = 0$ da como resultado el k -ésimo momento central al origen

Es decir, siguen el siguiente patrón:

- $\Psi'_X(t = 0) = E(X)$
- $\Psi''_X(t = 0) = E(X^2)$
- $\Psi'''_X(t = 0) = E(X^3)$
- $\Psi_X^{(n)}(t = 0) = E(X^n)$

3.7.3. Propiedades

- Nota que $\Psi_x(a) = E(e^{aX})$
- Si $Y = aX + b$ entonces tenemos que:
 $\Psi_Y(t) = e^{bt}\Psi_X(at)$

Demostración:

Esta esta fácil, sea $Y = aX + b$:

$$\begin{aligned}\Psi_Y(t) &= E(e^{tY}) \\ &= E(e^{t(aX+b)}) \\ &= E(e^{atX+tb}) \\ &= E(e^{atX} e^{tb}) \\ &= e^{tb} E(e^{atX}) \\ &= e^{tb} \Psi_X(at)\end{aligned}$$

- $\Psi_X(t = 0) = \mu_k$
- $\Psi_X(t = 0) = E(X)$
- Nota que si tuvieramos un montón de variables aleatorias $X_1, X_2, X_3, \dots, X_n$ Y decimos que $Y = \sum_{i=1}^n X_i$

Entonces tenemos que:

$$\Psi_Y(t) = \prod_{i=1}^n \Psi_{X_i}(t)$$

Demostración:

Esta también es importante:

$$\begin{aligned}\Psi_Y(t) &= E(e^{tY}) \\ &= E\left(e^{t \sum_{i=1}^n X_i}\right) \\ &= E\left(\prod_{i=1}^n e^{tX_i}\right) \\ &= \prod_{i=1}^n E(e^{tX_i}) \\ &= \prod_{i=1}^n \Psi_{X_i}(t)\end{aligned}$$

Capítulo 4

Distribuciones Famosas

4.1. Bernoulli

4.1.1. Definición

Suponte un experimento en el que solo tienes dos salidas, 0, 1, 0 para el fracaso y 1 para el éxito, suponte que la probabilidad de que salga 1 es p y la que salga 0 es $q = 1 - p$.

Variable Aleatoria

Ahora, nuestra variable aleatoria será:

X : Resultado del experimento

Ahora, los valores posibles que puede tomar son muy muy sencillos, básicamente porque solo hay 2 opciones, o salió bien, o salió mal, es decir X puede tomar los valores 0, 1.

Solemos entonces escribir esta distribución como:

$$X \sim Ber(x; p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito

4.1.2. Función Probabilidad

Esta es clásica:

$$f_X(x) = (p^x)((1-p)^{1-x}) = p^x q^{1-x}$$

Demostración:

Esta es fácil, podemos hacerla por partes, como parece más natural y ver que:

$$F_X(x) = \begin{cases} q & x = 0 \\ p & x = 1 \end{cases}$$

Podemos extender esta idea de muchas maneras a una expresión, la que damos es solo una de ellas.

4.1.3. Función P. Acumulada

Por definición tenemos que:

$$F_X(x) = \begin{cases} 0 & x < 0 \\ q & 0 \leq x < 1 \\ p & 1 \leq x \end{cases}$$

Y esta conviene mejor dejarla así.

4.1.4. Esperanza

Esta es la distribución con la esperanza más fácil que veras:

$$E(X) = p$$

Demostración:

Nota que por definición tenemos que:

$$\begin{aligned}\mu_X &= \sum_x xP(X = x) \\ &= 0(q) + 1(p) \\ &= p\end{aligned}$$

4.1.5. Varianza

Esta es igualmente sencilla:

$$v(X) = p(1 - p) = p - p^2 = pq$$

Demostración:

Por definición tenemos que:

$$\begin{aligned}v(X) &= E(x^2) - \mu^2 \\ &= E(x^2) - p^2 \\ &= \sum_x x^2 P(X = x) - p^2 \\ &= 0(q) + 1(p) - p^2 \\ &= p - p^2 \\ &= p(1 - p) \\ &= pq\end{aligned}$$

4.1.6. Función Generadora

Esta igual es muy bonita:

$$\Psi(t) = (q) + e^t(p)$$

Demostración:

Por definición tenemos que:

$$\begin{aligned}\Psi(t) &= E(e^t X) \\ &= \sum_x e^t x P(X = x) \\ &= e^{0t}(q) + e^{1t}(p) \\ &= (q) + e^t(p)\end{aligned}$$

4.2. Binomial

4.2.1. Definición

Un experimento binomial consiste en n ensayos Bernoulli independientes, con una probabilidad de éxito individual constante e igual en todos los experimentos

La variable aleatoria discreta nos medirá el número de éxitos de los experimentos individuales, donde sus posibles valores fueron $X = \{ 0, 1, \dots, n \}$.

Observa que la variable aleatoria se puede ver como la suma de Bernoullis independientes, es decir $X = X_1 + X_2 + X_3 + \dots + X_n$

Variable Aleatoria

Ahora, nuestra variable aleatoria será:

X : Número de Éxitos en los experimentos

Ahora, los valores posibles que puede tomar son muy muy sencillos, suponte que haremos n experimentos, entonces X tiene que tomar valores entre $0 \dots n$

Solemos entonces escribir esta distribución como:

$$X \sim \text{Bin}(x; n, p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito de cada experimento Bernoulli

Definición Alternativa

Sea X_i variables aleatorias de Bernoulli, tal que estén definidas por:

$$X_i = \begin{cases} 1 & \text{Si el } i \text{ésimo experimento fue exitoso} \\ 0 & \text{Si el } i \text{ésimo experimento fue un fallo} \end{cases} \quad \forall i \in [1, 2, \dots, n]$$

Nota que cada X_i es independiente

Entonces podemos ver a una Binomial como suma de Bernoulli INDEPENDIENTES es decir:

$$X = X_1 + X_2 + \dots + X_n$$

4.2.2. Función Probabilidad

Esta esta fácil:

$$f_X(x) = \binom{n}{x} p^x q^{n-x}$$

Demostración:

¿Porque? Porque estamos hablando de eventos independientes por lo tanto su probabilidad conjunta es el producto de las individuales, y literalmente estamos usando la definición de combinación.

4.2.3. Función P. Acumulada

Esta esta fácil:

$$F_X(x) = \sum_{i=0}^x \binom{n}{i} p^i q^{n-i}$$

Demostración:

Literalmente es la definición.

4.2.4. Esperanza

Esta también es sencilla:

$$E(X) = np$$

Demostración:

Podemos usar que la variable aleatoria se puede ver como la suma de Bernoullis independientes.

Es decir $X = \sum_x X_i$

$$\begin{aligned} \mu_X &= E(X) \\ &= E\left(\sum_x X_i\right) \\ &= \sum_x E(X_i) \\ &= np \end{aligned}$$

4.2.5. Varianza

Esta es bonita también:

$$v(X) = npq$$

Demostración:

Esta la haremos usando propiedades de la varianza, recuerda que son la suma de eventos independientes:

$$\begin{aligned} v(X) &= v\left(\sum_{i=0}^n X_i\right) \\ &= \sum_{i=1}^n v(X_i) \\ &= \sum_{i=1}^n pq \\ &= npq \end{aligned}$$

4.2.6. Función Generadora

Por definición tenemos que:

$$\Psi(t) = (q + e^t p)^n$$

Demostración:

Espera, espera, me explico mejor, lo que pasa es la binomial se puede ver como una suma de variables independientes entonces solo basta con recordar que ya demostramos que la función generadora de momentos de una suma de variables independientes es el producto de la función generadora de momentos de cada una.

Es decir:

$$\begin{aligned} \Psi_X(t) &= \Psi_{\sum_{i=1}^n X_i}(t) \\ &= \prod_{i=1}^n \Psi_{X_i}(t) \\ &= \prod_{i=1}^n (q + e^t p) \\ &= (q + e^t p)^n \end{aligned}$$

4.2.7. Propiedades

- Sean X_1, X_2, \dots, X_k k variables aleatorias discretas independientes y $X_i \sim \text{Bin}(x_i; n_i, p)$ con $i = 1, 2, \dots, k$.

Entonces la variable aleatoria $X = X_1 + X_2 + \dots + X_k$ tiene una distribución binomial tal que $X \sim \text{Bin}\left(x; \sum_{i=1}^k n_i, p\right)$

Demostración:

Veamos que:

$$\begin{aligned} \Psi_X(t) &= \Psi_{X_1+X_2+\dots+X_k}(t) \\ &= \prod_{i=1}^k \Psi_{X_i} \\ &= (q + pe^t)^{n_1} (q + pe^t)^{n_2} \dots (q + pe^t)^{n_k} \\ &= (q + pe^t)^{\sum_{i=1}^k n_i} \end{aligned}$$

Es decir $\Psi_X(t) = (q + pe^t)^n$ con $n = \sum_{i=1}^k n_i$, es decir vimos que $X \sim \text{Bin}\left(x; \sum_{i=1}^k n_i, p\right)$

4.3. Geométrica

4.3.1. Definición

Supón que se repiten de manera independiente ensayos Bernoulli con una probabilidad de éxito constante de p hasta obtener el primer éxito.

La variable discreta es el número de experimentos hasta un primer éxito, donde sus posibles valores son $X = \{ 1, 2, 3, \dots \}$.

Variable Aleatoria

Ahora, nuestra variable aleatoria será:

X : Número de experimentos hasta un éxito

Ahora, los valores posibles que puede tomar son muy muy sencillos, porque puede que pase en el primer experimento o en el segundo, es decir la variable aleatoria puede tomar cualquier valor en los enteros positivos.

Solemos entonces escribir esta distribución como:

$$X \sim G(x; p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito de cada experimento Bernoulli

4.3.2. Función Probabilidad

Esta esta fácil:

$$f_X(x) = q^{x-1} p$$

Es decir, es la propabilidad de que todos los anteriores sean fracasos y el actual sea el éxito.

4.3.3. Función P. Acumulada

Esta también es sencilla:

$$F_X(x) = 1 - q^x$$

Demostración:

Esta esta fácil, solo espero que recuerdes la suma de la serie geométrica:

$$\begin{aligned} F_X(x) &= \sum_{i=1}^x pq^{i-1} \\ &= (p) \sum_{i=0}^{x-1} q^i \\ &= (p) \frac{1 - q^x}{1 - q} \\ &= (p) \frac{1 - q^x}{p} \\ &= 1 - q^x \end{aligned}$$

4.3.4. Esperanza

Esta es muy famosa, y lo repito, que no se te olvide la geométrica

$$E(X) = \frac{1}{p}$$

Demostración:

$$\begin{aligned} E(X) &= \sum_{x=1}^{\infty} xP(X=x) \\ &= \sum_{x=1}^{\infty} xq^{x-1}p \\ &= p \sum_{x=1}^{\infty} xq^{x-1} \\ &= p \frac{d}{dx} \sum_{x=1}^{\infty} q^x \\ &= p \frac{d}{dx} \frac{1}{1-q} \\ &= p \frac{1}{(1-q)^2} \\ &= p \frac{1}{p^2} \\ &= \frac{1}{p} \end{aligned}$$

4.3.5. Varianza

Esta también es sencilla:

$$v(X) = \frac{1-p}{p^2}$$

Demostración:

$$\begin{aligned} v(X) &= E(X^2) - \mu^2 \\ &= E(X^2) - \frac{1}{p^2} \\ &= \sum_{x=1}^{\infty} x^2 P(X=x) - \frac{1}{p^2} \\ &= \sum_{x=1}^{\infty} x^2 pq^{x-1} - \frac{1}{p^2} \\ &= p \sum_{x=1}^{\infty} x^2 q^{x-1} - \frac{1}{p^2} \\ &= p \frac{1+q}{(1-q)^3} - \frac{1}{p^2} \\ &= \frac{1+q}{p^2} - \frac{1}{p^2} \\ &= \frac{q}{p^2} \\ &= \frac{1-p}{p^2} \end{aligned}$$

4.3.6. Función Generadora

Esta también saldra por definición no somos cobardes:

$$\Psi(t) = \frac{pe^t}{1 - qe^t}$$

Demostración:

Por definición tenemos que:

$$\begin{aligned}\Psi(t) &= E(e^{tX}) \\ &= \sum_{x=1}^{\infty} e^{tx} q^{x-1} p \\ &= p \sum_{x=1}^{\infty} e^{tx} q^{x-1} \\ &= p \sum_{x=1}^{\infty} e^{tx} q^{x-1} \\ &= pe^t \sum_{x=1}^{\infty} (qe^t)^{x-1} \\ &= pe^t \frac{1}{1 - qe^t} \\ &= \frac{pe^t}{1 - qe^t}\end{aligned}$$

4.3.7. Propiedades

- Sea $X \sim G(x; p)$ entonces tenemos que $P(X > a) = q^a$ con a un natural positivo

Demostración:

$$\begin{aligned} P(Y > a) &= 1 - F_X(a) && \text{Definición de Acumulada} \\ &= 1 - (1 - q^a) && \text{Talacha} \\ &= q^a && \text{Bingo} \end{aligned}$$

- Podemos decir que esta distribución no tiene memoria es decir que ya voy a experimentos y no ha pasado nada entonces, debería ya ser mas probable que para $a + b$ ya me tocará, me explico mejor ... ¿No? ¡Pues no!

Espera, me explico mejor:

Sea $X \sim G(x; p)$ entonces $P(X > a + b \mid X > a) = P(X > b)$ con a, b un naturales positivos

Demostración:

$$\begin{aligned} P(X > a + b \mid X > a) &= \frac{P(X > a + b \text{ y } X > a)}{P(X > a)} && \text{Definición de Condicional} \\ &= \frac{P(X > a + b)}{P(X > a)} && \text{Sentido común} \\ &= \frac{p^{a+b}}{p^a} && \text{Teorema pasado} \\ &= p^{(a+b)-a} && \text{Exponentes} \\ &= p^b && \text{Usando teorema pasado} \\ &= P(X > b) \end{aligned}$$

4.4. Hiper-Geométrica

4.4.1. Definición

Supongamos que tenemos una población de tamaño r , ahora esta particionado de 2 maneras, con elementos del tipo r_1 o r_2 , consideraremos exitosos los elementos de tipo r_1

Ahora vamos a tomar una muestra aleatoria de tamaño n sin reemplazo ni sustitución.

Ahora, solo por notación si es que n , es decir la muestra es menor que nuestra población r la llamamos muestra, pero si $n = r$ entonces decimos que es un censo.

Variable Aleatoria

Ahora, nuestra variable aleatoria sera:

X : Número de elementos del tipo r_1 en una muestra aleatoria de tamaño n

Ahora, los valores posibles que puede tomar son $\max(0, n - r_2) \leq x \leq \min(r_1, n)$

Ahora, ¿Porque esos números tan feos?

Por un lado tenemos que que lo peor que nos puede pasar son dos cosas:

- O bien si el tamaño de tu muestra n es muy pequeña, entonces puedes tener toda la mala suerte del mundo y que pase que todas caigan donde tu no querías por lo tanto, podría pasar que no seleccionará ningún elemento de r_1 entonces $X = 0$.
- Pero, pero que pasaría que tu n fuera lo suficientemente grande tal que incluso si seleccionará todos los que no quería r_2 , aún quedarán elementos por seleccionar, entonces los mínimos elementos r_1 que podría seleccionar es $n - r_2$, entonces $X = n - r_2$

El cálculo para el límite mayor es parecido

- Si tienes que $n \leq r_1$, entonces lo mejor que te puede pasar es que todos caigan donde tu quieras
- Si es que $n > r_1$ entonces puedes seleccionar todos los elementos de r_1

Solemos entonces escribir esta distribución como:

$$X \sim H(x; r_1, r_2, n)$$

donde:

- x : Nuestra variable
- r_1 : Tamaño de nuestra población de interes
- r_2 : Tamaño de la población que no es de interes, sale de $r_2 = r - r_1$
- n : Tamaño de la muestra

Definición Alternativa

Sea X_i variables aleatorias de Bernoulli, tal que esten definidas por:

$$X_i = \begin{cases} 1 & \text{Al sacar el elemento } i\text{-ésimo fue de tipo } r_1 \\ 0 & \text{Al sacar el elemento } i\text{-ésimo NO fue de tipo } r_1 \end{cases} \quad \forall i \in [1, 2, \dots, n]$$

Entonces podemos ver a una hipergeométrica como:

$$X = X_1 + X_2 + \dots + X_n$$

Lo importante aquí es que como cada una de ellas no son independientes

4.4.2. Función Probabilidad

Esta esta muy interesante, es:

$$f_X(x) = \frac{\binom{r_1}{x} \binom{r_2}{n-x}}{\binom{r}{n}}$$

Idea de la Demostración:

Antes que nada, mira lo bonito que sale, arriba tienes r_1, r_2 y $r_1 + r_2 = r$ y abajo tienes que $n - x, x$ y $n - x + x = n$

Ahora, abajo estamos colocando las posibles formas de escojer conjunto de n elementos de una espacio de r elementos, y arriba es la probabilidad conjunta de que primero tengamos x elementos de r_1 y $n - x$ elementos de r_2

4.4.3. Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = P(X \leq x) = \frac{1}{\binom{r}{n}} \sum_{i=\max(0, n-r_2)}^x \binom{r_1}{i} \binom{r_2}{n-i}$$

Idea de la Demostración:

Es por definición men :v

4.4.4. Esperanza

Esta esta muy interesante:

$$E(X) = n \left(\frac{r_1}{r} \right)$$

Demostración:

Primero que nada porque usando la definición o algo así nos van a salir cosas horribles, así que mejor empecemos por otro lado.

Sea X_i variables aleatorias de Bernoulli, tal que esten definidas por:

$$X_i = \begin{cases} 1 & \text{Al sacar el elemento } i\text{-ésimo fue de tipo } r_1 \\ 0 & \text{Al sacar el elemento } i\text{-ésimo NO fue de tipo } r_1 \end{cases}$$

Ahora, como son variables de Bernoulli, podemos encontrar bien facil su esperanza como $E(X_i) = p = \frac{r_1}{r}$

Ahora, como ya te esperabas, nota que nuestra variable aleatoria hipergeometrica es la suma de las otras $X = \sum_{i=1}^n X_i$

Ahora como la esperanza es un bonito operador lineal tenemos que:

$$\begin{aligned} E(X) &= E\left(\sum_{i=1}^n X_i\right) \\ &= \sum_{i=1}^n E(X_i) \\ &= \sum_{i=1}^n \frac{r_1}{r} \\ &= n \left(\frac{r_1}{r} \right) \end{aligned}$$

4.4.5. Varianza

Esta esta muy difícil, así que se deja para el lector :p

$$v(X) = n \left(\frac{r_1}{r} \right) \left(1 - \frac{r_1}{r} \right) \left(1 - \frac{n-1}{r-1} \right)$$

4.4.6. Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = E(e^{tX}) = \frac{1}{\binom{r}{n}} \sum_{i=\max(0, n-r_2)}^{\min(n, r_1)} e^{ti} \binom{r_1}{i} \binom{r_2}{n-i}$$

4.4.7. Relación con la Binomial

Suponte que tienes una población de r elementos, con r_1 de un tipo “bueno” y $r_2 := n - r$ de un tipo “malo”.

Ahora vamos a tomar una muestra aleatoria de tamaño n , sea entonces X : Número de elementos de tipo bueno en nuestra muestra

ahora podemos tener entonces 2 posibles distribuciones dependiendo de una pregunta clave.

¿Hay reemplazo?

■ **Si es que tiene Reemplazo:**

Entonces lo que pasa es que la probabilidad de éxito es constante, por lo tanto es simplemente n experimentos de tipo Bernoulli.

La probabilidad de éxito también es bastante sencilla de sacarse, es como $p = \frac{r_1}{r}$

Por lo tanto podemos decir que:

$$X \sim B(x; n, p)$$

Es decir, tendremos (como ya sabemos como se comporta una binomial):

- $E(X) = np = \frac{nr_1}{r}$
- $v(X) = npq = \frac{nr_1}{r} \left(1 - \frac{r_1}{r}\right)$

■ **Si es que NO tiene Reemplazo:**

Entonces lo que pasa es que la probabilidad de éxito ya no es constante, de hecho, llegamos a la definición de la Hipergeométrica, es decir:

Por lo tanto podemos decir que:

$$X \sim H(x; n, r_1, r_2)$$

Es decir, tendremos (como ya sabemos como se comporta una hipergeométrica):

- $E(X) = np = \frac{nr_1}{r}$
- $v(X) = npq = \frac{nr_1}{r} \left(1 - \frac{r_1}{r}\right) \left(1 - \frac{n-1}{r-1}\right)$

Es decir, sin importar si hay o no reemplazo, el valor esperado es el mismo, pero si es que no hay reemplazos tenemos una varianza es menor.

Podemos también darnos cuenta de que mientras más población la diferencia entre el reemplazo y sin reemplazo cada vez será menor.

4.5. Poisson

Variable Aleatoria

La variable aleatoria que cuenta el número de ocurrencias en un periodo de tiempo o espacio físico dado se le llama Poisson.

X : Número de ocurrencias en un periodo de tiempo o espacio dado

Ahora, los valores posibles que puede tomar es $0, 1, 2, \dots$

Solemos entonces escribir esta distribución como:

$$X \sim P(x; \lambda)$$

donde:

- x : Nuestra variable
- λ : Es el número promedio de ocurrencias en el periodo o espacio dado

4.5.1. Función Probabilidad

Esta esta muy interesante, es:

$$f_X(x) = P(X = x) = e^{-\lambda} \frac{\lambda^x}{x!}$$

4.5.2. Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = P(X \leq x) = e^{-\lambda} \sum_{i=0}^x \frac{\lambda^i}{i!}$$

Idea de la Demostración:

Es por definición men :v

4.5.3. Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = e^{\lambda(e^t-1)}$$

Demostración:

Usando la función probabilidad puntual tenemos que:

$$\begin{aligned}\Psi_X(t) &= E(e^{tX}) \\ &= \sum_{x=0}^{\infty} e^{tx} P(X = x) \\ &= \sum_{x=0}^{\infty} e^{tx} e^{-\lambda} \frac{\lambda^x}{x!} \\ &= e^{-\lambda} \sum_{x=0}^{\infty} e^{tx} \frac{\lambda^x}{x!} \\ &= e^{-\lambda} \sum_{x=0}^{\infty} \frac{(\lambda e^t)^x}{x!} \\ &= e^{-\lambda} e^{\lambda e^t} \\ &= e^{\lambda(e^t-1)}\end{aligned}$$

4.5.4. Esperanza

Esta esta muy interesante:

$$E(X) = \lambda$$

Demostración:

Esta sale o bien por definición o usando la generadora de momentos y diciendo que:

$$\begin{aligned}\Psi(t=0)' &= e^{\lambda(e^t-1)}\lambda(e^t) \Big|_{t=0} \\ &= e^0\lambda(e^0) \\ &= \lambda\end{aligned}$$

4.5.5. Varianza

Esta esta muy interesante:

$$v(X) = \lambda$$

Demostración:

Esta sale o bien por definición o usando la generadora de momentos y dicieno que:

$$\begin{aligned}\Psi(t=0)'' &= e^{\lambda(e^t-1)}\lambda(e^t) + \lambda(e^t)^2e^{\lambda(e^t-1)} \Big|_{t=0} \\ &= \lambda + \lambda^2\end{aligned}$$

Por lo tanto la varianza es $v(X) = \lambda + \lambda^2 - \lambda^2 = \lambda$

4.5.6. Relación con la Binomial

Considera $X \sim Bin(x; n, p)$, entonces cuando más grande sea n más nuestra binomial se va a parecer a una Poisson con $\lambda = np$

Demostración:

Considera $X \sim Bin(x; n, p)$, entonces esta más que claro que por ser una variable aleatoria que se distribuye con una binomial que $P(X = x) = f_X = \binom{n}{x} p^x q^{n-x}$.

Ahora como ya demostramos en las propiedades de la Poisson, vamos a suponer por un minuto que $\lambda = np$, es decir $p = \frac{\lambda}{n}$ entonces tenemos que:

$$P(X = x) = f_X = \binom{n}{x} p^x q^{n-x} = \binom{n}{x} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x}$$

Ahora veamos que es lo que pasa cuando tenemos una x muy muy grande, es decir:

$$\begin{aligned} \lim_{n \rightarrow \infty} P(X = x) &= \lim_{n \rightarrow \infty} \binom{n}{x} p^x q^{n-x} \\ &= \lim_{n \rightarrow \infty} \binom{n}{x} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \lim_{n \rightarrow \infty} \frac{n!}{x!(n-x)!} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \lim_{n \rightarrow \infty} \frac{n!}{x!(n-x)!} \frac{\lambda^x}{n^x} \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \lim_{n \rightarrow \infty} \frac{\lambda^x}{x!} \frac{n!}{n^x(n-x)!} \left(1 - \frac{\lambda}{n}\right)^{n-x} \\ &= \frac{\lambda^x}{x!} \lim_{n \rightarrow \infty} \frac{n-x+1}{n} \dots \frac{n-1}{n} \frac{n}{n} \left(1 - \frac{\lambda}{n}\right)^n \frac{1}{(n-\lambda)^x} \\ &= \frac{\lambda^x}{x!} e^{-\lambda} \lim_{n \rightarrow \infty} \frac{n-x+1}{n} \dots \frac{n-1}{n} \frac{1}{(n-\lambda)^x} \\ &= \frac{\lambda^x}{x!} e^{-\lambda} \lim_{n \rightarrow \infty} (1) \dots (1) \\ &= \frac{\lambda^x}{x!} e^{-\lambda} \end{aligned}$$

Por lo tanto cuando más grande sea n más nuestra binomial se va a parecer a una Poisson con $\lambda = np$

4.5.7. Propiedades

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim P(x_i; \lambda_i)$

Entonces $X = \sum_{i=1}^k X_i$ cumple que X se distribuye como una Poisson con parámetro $\lambda = \sum_{i=1}^k \lambda_i$

Demostración:

Sabes que para cada una de ellas tienes que $\Psi_{X_i}(t) = e^{\lambda_i(e^t-1)}$ entonces al ser una suma de variables aleatorias tenemos que su generadora es el producto de cada generadora, es decir:

$$\begin{aligned}\Psi_X(t) &= \prod_{i=1}^k \Psi_{X_i}(t) \\ &= \prod_{i=1}^k e^{\lambda_i(e^t-1)} \\ &= e^{(\sum_{i=1}^k \lambda_i)(e^t-1)}\end{aligned}$$

Es decir se parece muchísimo a una Poisson con una lamda igual a $\lambda = \sum_{i=1}^k \lambda_i$

Parte III

Variables Aleatorias Continuas

Capítulo 5

Variables Aleatorias Continuas

5.1. Variables Aleatorias

Una variable aleatoria es una función que asigna a cada elemento $E_i \in S$ en el espacio muestral a un número real $X(E_i) \in \mathbb{R}$, es decir, en español, lo que hace es que es una función que nos da información de una característica de cada elemento del espacio muestral.

5.1.1. Variables Aleatorias Continuas

Las variables aleatorias cuyo conjunto de valores posibles es el de los números reales, nos permiten medir un parámetro continuo.

Recuerda que los números reales son densos, eso quiere decir que entre cuales quiera dos reales, podemos encontrar otro real entre ambos.

Obviamente se conservan prácticamente todas las propiedades de cuando trabajamos con las variables aleatorias discretas.

5.2. Función Probabilidad f_X

5.2.1. Definición

Vamos a definir a la función de probabilidad de una variable aleatoria continua como aquella función $f_X(x)$ para la cual siempre se cumplan 2 cosas:

- $\int_{-\infty}^{\infty} f_X(x) dx = 1$
- $P(a < X < b) = \int_a^b f_X(x) dx$

Recuerda que las probabilidades en el caso continuo se puede ver como áreas bajo la curva delimitada según el interes.

5.2.2. Probabilidad Puntual

También se le conoce como función de probabilidad puntual. Es tecnicamente la misma que en las variables aleatorias discretas, pero al estar hablando de puede tomar cualquier real, entonces decimos que:

$$P(X = x) = 0$$

Esto nos lleva una propiedad muy importante que vamos a ocupar a cada rato:

$$P(a < X < b) = P(a < X \leq b) = P(a \leq X < b) = P(a \leq X \leq b)$$

Demostración:

- $P(a < X \leq b) = P(a < X < b) + P(b) = P(a < X < b) + 0 = P(a < X < b)$
- $P(a \leq X < b) = P(a < X < b) + P(a) = P(a < X < b) + 0 = P(a < X < b)$
- $P(a \leq X \leq b) = P(a < X < b) + P(a) + P(b) = P(a < X < b) + 0 + 0 = P(a < X < b)$

5.3. Función P. Acumulada F_X

5.3.1. Definición

Vamos a definir a la función de distribución o acumulada como:

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(x) dx$$

Recuerda que las probabilidades en el caso continuo se puede ver como áreas bajo la curva delimitada según el interes.

5.3.2. Propiedades

- $f_X(x) = \frac{d F_X(x)}{dx}$ si es que tiene sentido la derivada en ese punto sino $f_X(x) = 0$

5.4. Esperanza

5.4.1. Definición

Vamos a definir a la esperanza de una variable aleatoria continua como:

$$E(x) = \mu_X = \int_{-\infty}^{\infty} x f_X(x) dx$$

5.5. Varianza

5.5.1. Definición

Vamos a definir a la varianza de una variable aleatoria continua como:

$$\begin{aligned} v(x) &= \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x) dx \\ &= \left(\int_{-\infty}^{\infty} x^2 f(x) dx \right) - \mu_x^2 \end{aligned}$$

5.6. Función Generadora de Momentos

5.6.1. Definición

Vamos a definir a la esperanza de una variable aleatoria continua como:

$$\Psi_X(t) = E(e^{tX}) = \int_{-\infty}^{\infty} e^{tx} f_X(x) dx$$

Capítulo 6

Distribuciones Continuas Famosas

6.1. Uniforme

6.1.1. Definición

La mas sencilla de todas las distribuciones continuas es la uniforme.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $a < x < b$.

Solemos entonces escribir esta distribución como:

$$X \sim U(x; a, b)$$

donde:

- a : Inicio de la muestra
- b : Fin de la muestra

6.1.2. Función Probabilidad

Esto es lo que distingue a una distribución uniforme:

$$f_X(x) = \begin{cases} \frac{1}{b-a} & a < x < b \\ 0 & \text{en otro caso} \end{cases}$$

Idea de la Demostración:

La razón de que sea así es que tiene que cumplir que $\int_{-\infty}^{\infty} f(x)dx = 1$ y claro que lo cumple:

$$\begin{aligned} \int_{-\infty}^{\infty} f(x)dx &= \int_a^b \frac{1}{b-a} dx \\ &= \frac{1}{b-a} \int_a^b dx \\ &= \frac{1}{b-a} [b-a] \\ &= 1 \end{aligned}$$

6.1.3. Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = \frac{x-a}{b-a}$$

Idea de la Demostración:

Es por definición men :v

$$\begin{aligned} F_X(x) &= \int_{-\infty}^x f(x)dx \\ &= \int_a^x \frac{1}{b-a} dx \\ &= \frac{1}{b-a} \int_a^x dx \\ &= \frac{x-a}{b-a} \end{aligned}$$

6.1.4. Esperanza

Esta esta muy interesante:

$$E(X) = \frac{a+b}{2}$$

Demostración:

Esta también sale bonita:

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x f_X(x) dx \\ &= \int_a^b x \frac{1}{b-a} dx \\ &= \left(\frac{1}{b-a} \right) \int_a^b x dx \\ &= \left(\frac{1}{b-a} \right) \frac{b^2 - a^2}{2} \\ &= \left(\frac{1}{b-a} \right) \frac{(b-a)(b+a)}{2} \\ &= \frac{a+b}{2} \end{aligned}$$

6.1.5. Varianza

Esta esta muy difícil, pero si se puede:

$$v(X) = \frac{(a - b)^2}{12}$$

Demostración:

Primero hay que hacer que:

$$\begin{aligned} E(X^2) &= \int_{-\infty}^{\infty} x^2 f_X(x) dx \\ &= \int_a^b x^2 \frac{1}{b-a} dx \\ &= \left(\frac{1}{b-a} \right) \int_a^b x^2 dx \\ &= \left(\frac{1}{b-a} \right) \frac{b^3 - a^3}{3} \\ &= \left(\frac{1}{b-a} \right) \frac{(b-a)(b^2 + ab + a^2)}{3} \\ &= \frac{b^2 + ab + a^2}{3} \end{aligned}$$

Ahora podemos sacar a la varianza:

$$\begin{aligned} v(X) &= E(X^2) - \mu_X^2 \\ &= E(X^2) - \frac{(a+b)^2}{4} \\ &= \frac{b^2 + ab + a^2}{3} - \frac{a^2 + 2ab + b^2}{4} \\ &= \frac{4b^2 + 4ab + 4a^2}{12} - \frac{3a^2 + 6ab + 3b^2}{12} \\ &= \frac{a^2 + b^2 - 2ab}{12} \\ &= \frac{(a-b)^2}{12} \end{aligned}$$

6.1.6. Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = \frac{e^{bt} - e^{at}}{t(b-a)}$$

Demostración:

Ahora vamos a demostrarlo:

$$\begin{aligned} E(e^{tX}) &= \int_{-\infty}^{\infty} e^{tx} f_X(x) dx \\ &= \left(\frac{1}{b-a} \right) \int_a^b e^{tx} dx \\ &= \left(\frac{1}{b-a} \right) \frac{e^{bt} - e^{at}}{t} \\ &= \frac{e^{bt} - e^{at}}{t(b-a)} \end{aligned}$$

6.2. Exponencial

6.2.1. Definición

Se utiliza generalmente para representar una distribución del tiempo que transcurre antes de la ocurrencia de un suceso.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $x > 0$

Solemos entonces escribir esta distribución como:

$$X \sim E(x; \beta)$$

donde:

- β : Es un parámetro que tiene que ser un entero positivo

6.2.2. Función Probabilidad

Esto es lo que distingue a una distribución exponencial:

$$f_X(x) = \begin{cases} \beta e^{-\beta x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

6.2.3. Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = 1 - e^{-\beta x}$$

Idea de la Demostración:

Es por definición men :v

$$\begin{aligned} F_X(x) &= \int_{-\infty}^x f(t) dt \\ &= \int_0^x \beta e^{-\beta t} dt \\ &= -e^{-\beta t} \Big|_0^x \\ &= 1 - e^{-\beta x} \end{aligned}$$

6.2.4. Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = \frac{\beta}{\beta - t}$$

Demostración:

Ahora vamos a demostrarlo:

$$\begin{aligned} E(e^{tX}) &= \int_{-\infty}^{\infty} e^{tx} f_X(x) dx \\ &= \int_0^{\infty} e^{tx} \beta e^{-\beta x} dx \\ &= \beta \int_0^{\infty} e^{(t-\beta)x} dx \\ &= \beta \frac{1}{t-\beta} e^{(t-\beta)x} \Big|_0^{\infty} \\ &= \beta \frac{1}{t-\beta} (-1) \\ &= \frac{\beta}{\beta - t} \end{aligned}$$

6.2.5. Esperanza

Esta esta muy interesante:

$$E(X) = \frac{1}{\beta}$$

Demostración:

Esta también sale bonita:

$$\begin{aligned} E(X) &= \Psi'_X(0) \\ &= \frac{d}{dx} t \frac{\beta}{\beta - t} \Big|_0 \\ &= \frac{\beta}{(\beta - t)^2} \Big|_0 \\ &= \frac{\beta}{(\beta)^2} \\ &= \frac{1}{\beta} \end{aligned}$$

6.2.6. Varianza

Esta esta muy difícil, pero si se puede:

$$v(X) = \frac{1}{\beta^2}$$

Demostración:

$$\begin{aligned} E(X^2) &= \Psi_X''(0) \\ &= \frac{d}{dx} \frac{\beta}{(\beta - t)^2} \Big|_0 \\ &= \frac{2\beta}{(\beta - t)^3} \Big|_0 \\ &= \frac{2\beta}{(\beta)^3} \\ &= \frac{2}{\beta^2} \end{aligned}$$

Entonces la varianza sale rapido:

$$\begin{aligned} v(X) &= E(X^2) - \mu_X^2 \\ &= \frac{2}{\beta^2} - \frac{1}{\beta^2} \\ &= \frac{1}{\beta^2} \end{aligned}$$

6.2.7. Propiedades

- Podemos decir que esta distribución no tiene memoria, me explico mejor.

Sea $P(X > a + b \mid X > a) = P(X > b)$ con a, b un naturales positivos

Demostración:

$$\begin{aligned} P(X > a + b \mid X > a) &= \frac{P(X > a + b \text{ y } X > a)}{P(X > a)} \\ &= \frac{P(X > a + b)}{P(X > b)} \\ &= \frac{1 - F_X(a + b)}{1 - F_X(b)} \\ &= \frac{e^{-a\beta - b\beta}}{e^{-b\beta}} \\ &= e^{-b\beta} \end{aligned}$$

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim E(x_i; \beta)$

Entonces $X = \min(X_1, X_2, \dots, X_k)$ también cumple que X se distribuye como una Exponencial con parámetro $\beta = n\beta$

Demostración:

Esa sale rápido:

$$\begin{aligned} P(X > t) &= P(X_1 > t)P(X_2 > t) \dots (X_k > t) \\ &= e^{-t\beta} \dots e^{-t\beta} \\ &= e^{-t(n\beta)} \end{aligned}$$

Es decir se parece muchísimo a una Exponencial con una beta igual a $\beta = n\beta$

- Sea $X_1, X_2, \dots, X_\alpha$ variables aleatorias independientes y $X_i \sim E(x_i; \beta)$

Entonces $X = X_1 + X_2 + \dots + X_\alpha$ se distruye como como $X \sim \Gamma(x; \alpha, \beta)$

Demostración:

Nota que:

$$\Psi_{X_i}(t) = \frac{\beta}{\beta - t}$$

Entonces tenemos que:

$$\begin{aligned} \Psi_X(t) &= \prod_{i=1}^{\alpha} \frac{\beta}{\beta - t} \\ &= \left(\frac{\beta}{\beta - t} \right)^\alpha \end{aligned}$$

Es decir, es una función generadora de la gamma, y ya :v

6.3. Gamma

6.3.1. Función Gamma

La función Gamma se puede ver para $a > 0$ como:

$$\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx$$

Propiedades

La función gamma tiene un par de propiedades interesantes

- $\Gamma(1) = 1$

Demostración:

Nota que:

$$\begin{aligned} \Gamma(1) &= \int_0^{\infty} x^{1-1} e^{-x} dx \\ &= \int_0^{\infty} e^{-x} dx \\ &= -e^{-x} \Big|_0^{\infty} \\ &= e^0 - 0 \\ &= 1 \end{aligned}$$

- $\Gamma(a) = (a - 1)\Gamma(a - 1)$

Demostración:

Esto es clave:

$$\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx$$

Esta se puede intentar resolver por partes, entonces tenemos que:

- $u = x^{a-1}$
- $du = (a - 1)x^{a-2} dx$
- $dv = e^{-x}$
- $v = -e^{-x}$

Entonces decimos que:

$$\begin{aligned} \Gamma(a) &= \int_0^{\infty} x^{a-1} e^{-x} dx \\ &= -x^{a-1} e^{-x} \Big|_0^{\infty} + \int_0^{\infty} e^{-x} (a - 1)x^{a-2} dx \\ &= \Gamma(a) = (a - 1)\Gamma(a - 1) \end{aligned}$$

- Si $n \in \mathbb{Z}^+$ entonces $\Gamma(n) = (n - 1)!$

Demostración:

Es simplemente recursividad es decir:

$$\begin{aligned}\Gamma(n) &= (n - 1)\Gamma(n - 2) \\ &= (n - 1)(n - 2)\Gamma(n - 3) \\ &= \dots \\ &= (n - 1)!\end{aligned}$$

6.3.2. Definición

Se utiliza generalmente para representar una distribución del tiempo que transcurre antes de la ocurrencia de un suceso.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $x > 0$

Solemos entonces escribir esta distribución como:

$$X \sim \Gamma(x; a, \beta)$$

donde:

- a : Entero positivo
- β : Es un parámetro que tiene que ser un entero positivo

6.3.3. Función Probabilidad

Esto es lo que distingue a una distribución gamma:

$$f_X(x) = \begin{cases} \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

6.3.4. Función Acumulada

Esta esta rara, pero ve que.

$$F_X(x) = 1 - F_X^P(\alpha - 1) \quad \text{Con } \lambda = \beta x$$

Es decir:

$$F_X(x) = 1 - e^{-\beta x} \sum_{i=0}^{\alpha-1} \frac{(\beta x)^i}{i!}$$

Demostración:

Esta esta bien genial: Primero veamos que lo que queremos sacar es:

$$P(X \geq x) = \frac{\beta^\alpha}{\Gamma(\alpha)} \int_x^\infty x^{\alpha-1} e^{-\beta x} dx$$

Ahora hay que notar al patrón que sale de hacer por partes:

$$\begin{aligned} P(X \geq x) &= \frac{\beta^\alpha}{\Gamma(\alpha)} \int_x^\infty x^{\alpha-1} e^{-\beta x} dx \\ &= \frac{(\beta x)^{\alpha-1}}{\Gamma(\alpha-1)!} e^{-\beta x} + \frac{(\beta x)^{\alpha-2}}{\Gamma(\alpha-2)!} e^{-\beta x} + \frac{(\beta x)^{\alpha-3}}{\Gamma(\alpha-3)!} e^{-\beta x} + \dots \end{aligned}$$

Ahora ve que α es un entero positivo

Por lo tanto tenemos que:

$$P(X \geq x) = \sum_{i=0}^{\alpha-1} -1 \frac{(\beta x)^i}{\Gamma(i)!} e^{-\beta x}$$

Nota que esto no es más que una Poisson, más explícitamente tenemos que:

$$\sum_{i=0}^{\alpha-1} -1 \frac{(\beta x)^i}{\Gamma(i)!} e^{-\beta x} = F_X^P(\alpha - 1)$$

Entonces nos damos cuenta al final que:

$$F_X(x) = 1 - P(X \geq x) = 1 - F_X^P(\alpha - 1)$$

Donde tenemos que $\alpha = \beta x$

6.3.5. Generadora de Momentos

Esto es sencillo:

$$\Psi_X(t) = \left(\frac{\beta}{\beta - t} \right)^\alpha$$

Demostración:

$$\begin{aligned} \Psi_X(t) &= E(e^{tX}) \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \int_{-\infty}^{\infty} e^{tx} x^{\alpha-1} e^{-\beta x} dx \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \int_{-\infty}^{\infty} e^{-x(\beta-t)} x^{\alpha-1} dx \end{aligned}$$

Ahora vemos que: $x = \frac{u}{\beta-t}$ $u = [\beta - t]x \rightarrow du = [\beta - t]dx$ to $dx = \frac{du}{\beta-t}$

Ahora vemos que:

$$\begin{aligned} \Psi_X(t) &= \frac{\beta^\alpha}{\Gamma(\alpha)} \int_{-\infty}^{\infty} \left[\frac{u}{\beta-t} \right]^{\alpha-1} e^{-u} \frac{du}{\beta-t} \\ &= \frac{\beta^\alpha}{(\beta-t)^\alpha \Gamma(\alpha)} \int_0^{\infty} u^{\alpha-1} e^{-u} du \\ &= \frac{\beta^\alpha}{(\beta-t)^\alpha} \\ &= \left(\frac{\beta}{\beta-t} \right)^\alpha \end{aligned}$$

6.3.6. Esperanza

Usando la función generadora tenemos que:

$$E(X) = \frac{\alpha}{\beta}$$

Demostración:

$$\begin{aligned} E(X) &= \Psi'_X(0) \\ &= \frac{d}{dx} t \left[\frac{\beta}{\beta - t} \right]^\alpha \Big|_{t=0} \\ &= \beta^\alpha \frac{d}{dx} t (\beta - t)^{-\alpha} \Big|_{t=0} \\ &= \beta^\alpha \alpha (\beta - t)^{-\alpha-1} \Big|_{t=0} \\ &= \beta^\alpha \alpha \beta^{-\alpha-1} \\ &= \frac{\alpha}{\beta} \end{aligned}$$

6.3.7. Varianza

Usando la función generadora tenemos que:

$$v(X) = \frac{\alpha}{\beta^2}$$

Demostración:

$$\begin{aligned} E(X^2) &= \Psi''_X(0) \\ &= \beta^\alpha \alpha \frac{d}{dx} t [\beta - t]^{-\alpha-1} \Big|_{t=0} \\ &= \beta^\alpha \alpha (-\alpha - 1) \frac{d}{dx} t [\beta - t]^{-\alpha-2} (-1) \Big|_{t=0} \\ &= \beta^\alpha \alpha (\alpha + 1) \frac{d}{dx} t [\beta - t]^{-\alpha-2} \Big|_{t=0} \\ &= \beta^\alpha \alpha (\alpha + 1) \beta^{-2} \\ &= \frac{\alpha(\alpha + 1)}{\beta^2} \end{aligned}$$

Por lo tanto finalmente tenemos que:

$$\begin{aligned} v(X) &= E(X^2) - E(X)^2 \\ &= \frac{\alpha(\alpha + 1)}{\beta^2} - \left(\frac{\alpha}{\beta} \right)^2 \\ &= \frac{\alpha}{\beta^2} \end{aligned}$$

6.3.8. Propiedades

- Si tenemos una distribución Gamma pero donde $\alpha = 1$, entonces lo que en realidad tenemos es una distribución exponencial con la misma β
- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim \Gamma(x_i; \alpha_i, \beta)$
Entonces $X = X_1 + X_2 + \dots + X_k$ se distribuye como como $X \sim \Gamma(x; \sum_{i=1}^k \alpha_i, \beta)$

Demostración:

Nota que:

$$\Psi_{X_i}(t) = \left(\frac{\beta}{\beta - t} \right)^\alpha$$

Entonces tenemos que:

$$\begin{aligned} \Psi_X(t) &= \prod_{i=1}^k \left(\frac{\beta}{\beta - t} \right)^\alpha \\ &= \left(\frac{\beta}{\beta - t} \right)^{\sum_{i=1}^k \alpha_i} \end{aligned}$$

Es decir, es una función generadora de la gamma, y ya :v

6.4. Normal

6.4.1. Definición

Es la más famosa de todas las continuas, es simétrica con respecto al valor central μ

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria son todos los reales

Solemos entonces escribir esta distribución como:

$$X \sim N(x; \mu, \sigma^2)$$

donde:

- μ : El valor central, es cualquier real
- σ^2 : La varianza, es un real positivo

Nota que si pasa que $X \sim N(x; \mu = 0, \sigma^2 = 1)$ entonces se suele denotar como:
 $Z \sim N(0, 1)$

Se le conoce como normal estandar.

6.4.2. Estandarización

Ya que tenemos una normal estandar, es decir una que cumple que $\mu = 0, \sigma^2 = 1$

Ahora, hay una forma muy fácil de “estandarizar” es decir de transformar cualquier punto sobre una normal a ese punto en la estandar esta dada por:

$$Z = \frac{X - \mu}{\sigma}$$

Demostración:

Lo que hacemos es primero sacar la distancia al punto central, una vez que lo tengamos lo que hacemos es dividir entre la desviación estandar porque es una nueva escala una que nunca cambia.

Y obviamente tiene su inversa:

$$X = Z\sigma + \mu$$

6.4.3. Función Probabilidad

Esto es lo que distingue a una distribución uniforme:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

Demostración que es una función de Probabilidad:

Supon que $I = \int_{-\infty}^{\infty} f_X(x)dx$, por lo tanto basta con hacer demostrar que $I^2 = 1$.

Primero haremos el cambio de variable a $u = \frac{x-\mu}{\sigma}$ y $du = \frac{dx}{\sigma}$, es decir, vamos a mejor resolver la estandar:

$$I = \int_{-\infty}^{\infty} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du$$

Entonces decimos ahora que:

$$I^2 = \frac{1}{2\pi} \left(\int_{-\infty}^{\infty} e^{-\frac{1}{2}u^2} du \right)^2 \tag{6.1}$$

$$= \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(u^2+v^2)} dudv \tag{6.2}$$

Ahora simplemente cambiamos a coordenada polares:

$$I^2 = \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(u^2+v^2)} dudv \tag{6.3}$$

$$= \frac{1}{2\pi} \int_0^{2\pi} \int_0^{\infty} e^{-\frac{r^2}{2}} r dr d\theta \tag{6.4}$$

$$= \frac{1}{2\pi} \int_0^{2\pi} \left[-e^{-\frac{r^2}{2}} \Big|_0^{\infty} \right] d\theta \tag{6.5}$$

$$= \frac{1}{2\pi} \int_0^{2\pi} d\theta \tag{6.6}$$

$$= \frac{1}{2\pi} \theta \Big|_0^{2\pi} \tag{6.7}$$

$$= 1 \tag{6.8}$$

6.4.4. Generadora de Momentos

Esta es sencilla:

$$\Psi_X(t) = e^{t\mu + \frac{1}{2}(t^2\sigma^2)}$$

Demostración:

Hagamos la definición:

$\Psi_X(t) = \int_{-\infty}^{\infty} e^{tx} f_x dx$	Por definición
$= \int_{-\infty}^{\infty} e^{tx} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} dx$	Definición igual :v
$= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{t(\mu+\sigma u) - \frac{1}{2}u^2} du$	La hacemos estandar $u = \frac{x-\mu}{\sigma}$ y $du = \frac{dx}{\sigma}$
$= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{t\mu} e^{-\frac{1}{2}(u^2 - 2t\sigma u)} du$	Ponemos bonito
$= \frac{e^{t\mu}}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(u^2 - 2t\sigma u + (t^2\sigma^2) - (t^2\sigma^2))} du$	Ponemos bonito
$= \frac{e^{t\mu + \frac{1}{2}(t^2\sigma^2)}}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(u^2 - 2t\sigma u + (t^2\sigma^2))} du$	Completamos el cuadrado
$= \frac{e^{t\mu + \frac{1}{2}(t^2\sigma^2)}}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{1}{2}(z)^2} dz$	$z = u - t\sigma$ $dz = du$
$= e^{t\mu + \frac{1}{2}(t^2\sigma^2)} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(z)^2} dz$	Acomodo para hacer una normal estandar
$= e^{t\mu + \frac{1}{2}(t^2\sigma^2)}$	Recuerda que por ser función de probabilidad

6.4.5. Media

Mira, que loco :v

$$E(X) = \mu$$

Demostración:

Mira, que bonito es todo:

$$\begin{aligned} E(X) &= \Psi_X(0)' \\ &= e^{t\mu + \frac{1}{2}(t^2\sigma^2)} \left[\mu + \frac{2t\sigma^2}{2} \right] \Big|_0 \\ &= e^0(\mu) \\ &= \mu \end{aligned}$$

6.4.6. Varianza

Mira, que loco :v

$$v(X) = \sigma^2$$

Demostración:

Mira, que bonito es todo:

$$\begin{aligned} v(X) &= E(X^2) - \mu^2 \\ &= \Psi_X(0)'' - \mu^2 \\ &= \mu^2 + \sigma^2 - \mu^2 \\ &= \sigma^2 \end{aligned}$$

6.4.7. Propiedades

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim N(x_i; \mu_i, \sigma_i^2)$

Entonces $X = X_1 + X_2 + \dots + X_k$ se destruye como como $X \sim N(x_i; \sum_{i=1}^k \mu_i, \sum_{i=1}^k \sigma_i^2)$

Demostración:

Empecemos por ver que $X_i \sim N(x; \mu_i, \sigma_i^2)$ Es decir $\Psi_{X_i}(t) = e^{t\mu_i + \frac{1}{2}(t^2\sigma_i^2)}$ entonces vemos que:

$$\begin{aligned}\Psi_X(t) &= \Psi_{\sum_{i=1}^n X_i}(t) \\ &= \prod_{i=1}^n \Psi_{X_i}(t) \\ &= e^{\sum_{i=1}^n t\mu_i + \frac{1}{2}(t^2\sigma_i^2)} \\ &= e^{t(\sum_{i=1}^n \mu_i) + \frac{1}{2}(t^2(\sum_{i=1}^n \sigma_i^2))}\end{aligned}$$

Por lo tanto como puedes ver tiene una media de $\mu_X = \sum_{i=1}^n \mu_i$ y una varianza de $\sigma_X^2 = \sum_{i=1}^n \sigma_i^2$

- Sea $X_i \sim N(x_i; \mu, \sigma^2)$

Entonces $Y = aX + b$ se destruye como como $Y \sim N(y; a\mu + b, a\sigma^2)$

Demostración:

Empecemos por ver que $X \sim N(x; \mu, \sigma^2)$ entonces vemos que:

$$\begin{aligned}\Psi_Y(t) &= E(e^{tY}) \\ &= E(e^{t(aX+b)}) \\ &= e^{tb} E(e^{taX}) \\ &= e^{tb} \Psi_X(at) \\ &= e^{tb} e^{at\mu + \frac{1}{2}a^2t^2\sigma^2} \\ &= e^{t(b+a\mu) + \frac{1}{2}a^2t^2\sigma^2}\end{aligned}$$

Por lo tanto como puedes ver tiene una media de $\mu_Y = a\mu + b$ y una varianza de $\sigma_Y^2 = a^2\sigma^2$

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim N(x_i; \mu, \sigma^2)$

Entonces $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ se destruye como como $\bar{X} \sim N(\bar{x}; \mu, \frac{\sigma^2}{n})$

Demostración:

Colorario joven, es un colorario :v

Capítulo 7

Probabilidad Hardcore

7.1. Teorema Central del Límite

7.1.1. Definición

Garantiza que para n (tamaño de muestra) suficientemente grande ($n \geq 30$) entonces:

- Si tienes una variable aleatoria que es la media muestral de otras variables aleatorias entonces mientras mas variables aleatoria muestrees entonces más se va aproximar:

$$\bar{X} \approx N(x; \mu = \mu, \sigma^2 = \frac{\sigma^2}{n})$$

- Si tienes una variable aleatoria que esta compuesta por la suma de muchas otras variables aleatorias entonces mientras mas grande sea la cantidad de variables aleatorias más se aproxima a una normal:

$$\sum_{i=0}^n X_i \approx N(x; \mu_x = n\mu, \sigma_x^2 = n\sigma^2)$$

7.2. Teorema Central de Chebyshe

7.2.1. Definición

Si no se conoce la distribución de la variable aleatoria, pero por circunstancias raras tengamos la media y la varianza entonces podemos conocer información de la variable.

Tenemos que:

$$P(\mu - k\sigma \leq X \leq \mu + k\sigma) \geq 1 - \frac{1}{k^2}$$

$$P(|X - \mu| \leq k\sigma) \geq 1 - \frac{1}{k^2}$$

$$P(|X - \mu| > k\sigma) < \frac{1}{k^2}$$

Parte IV

Probabilidades Conjuntas

Capítulo 8

Variables A. Multidimensionales

8.1. Función de Probabilidad

La función de probabilidad conjunta de una variable bidimensional se puede ver de dos maneras:

8.1.1. Discreto

La definimos como:

$$f_{X,Y}(x, y) := P(X = x, Y = y)$$

Y cumple con que:

- $P(X = x, Y = y) \in [0, 1]$
- $\sum_y \sum_x P(X = x, Y = y) = 1$

8.1.2. Continuo

Es la función de dos variables que cumple que:

- $f_{X,Y}(x, y) > 0 \forall x, y$
- $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy dx = 1$

Ahora en el rango de los posibles valores de la variable aleatoria bidimensional en el caso de continuo serán regiones en el plano y las probabilidades de interés serán volúmenes bajo la curva de interés.

8.2. Distribución Acumulada

8.2.1. Discreto

La definimos como:

$$F_{X,Y} := P(X \leq x, Y \leq y)$$

8.2.2. Continuo

La definimos como:

$$F_{X,Y} := \int_{-\infty}^y \int_{-\infty}^x f_{X,Y}(x, y) dx dy$$

Nota que $\frac{\partial^2}{\partial x \partial y} F_{X,Y}(x, y) = f_{X,Y}(x, y)$

8.3. Distribución Marginal

8.3.1. Discreto

La definimos de 2 maneras:

$$\blacksquare f_X(x) := \sum_y P(X = x, Y = y)$$

$$\blacksquare f_Y(y) := \sum_x P(X = x, Y = y)$$

8.3.2. Continuo

$$\blacksquare f_X(x) := \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy$$

$$\blacksquare f_Y(y) := \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx$$

8.4. Distribución Condicional

8.4.1. Discreto

Podemos definirlo como:

$$f_{X|y}(x|y) = \frac{P(X = x, Y = y)}{P(Y = y)} \quad \forall x$$

Sus valores posibles son los valores de la variable aleatoria X .

Tenemos una distribución diferente para cada valor de Y

8.4.2. Continuo

Podemos definirlo como:

$$f_{X|y}(x|y) = \frac{f_{X,Y}(x, y)}{f_Y(y)}$$

Sus valores posibles son los valores de la variable aleatoria X .

Tenemos una distribución diferente para cada valor de Y

8.5. Independencia de Variables

Sea una variable aleatoria dimensional X, Y , son independientes si y solo si:

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

O dicho en otras palabras:

$$f_{X,Y}(x, y) = f_X(x)f_Y(y)$$

8.5.1. Propiedades

- X, Y son linealmente independientes si y solo si $P(X = x|Y = y) = P(X = x)$ o dicho de otra manera si $f_{X|Y}(x, y) = f_X(x)$

Parte V

Estimaciones

Capítulo 9

Estimadores Puntuales

9.1. Características

9.1.1. Insesgado

Sesgo

Este esta dado por:

$$Sesgo(\hat{\theta}) = E(\hat{\theta}) - \theta$$

Definición

Suponte que tenemos un estimador puntual $\hat{\theta}$, decimos que es insesgado si y solo si $E(\hat{\theta}) = \theta$

9.1.2. Varianza Mínima

Antes que nada vayamos con las definiciones:

Error Cuadrático Medio

Este esta dado por:

$$ECM(\hat{\theta}) = E(\theta - \hat{\theta})^2$$

Podemos trabar un poco la definición y llegar a una alternativa que puede sernos mucho más útil

$$ECM(\hat{\theta}) = V(\hat{\theta}) + Sesgo(\hat{\theta})$$

Si tenemos un estimador insesgado entonces es más que obvio que:

$$ECM(\hat{\theta}) = V(\hat{\theta})$$

9.1.3. Optimo

Decimos que un estimador es optimo si cumple que:

$$ECM(\hat{\theta}) < ECM(\hat{\theta}_x) \forall \theta_x$$

9.1.4. Optimo

Decimos que un estimador es consistente si cumple que siendo n el tamaño de la muestra:

$$\lim_{n \rightarrow \infty} ECM(\hat{\theta}) = 0$$

9.2. Método de los Momentos

Podemos usar los momentos para estimar parámetros, de la siguiente manera:

- El k-ésimo momento poblacional es $\mu_k = E(X^K)$
- El k-ésimo momento muestral es $\mu_k = \frac{1}{n} \sum_{i=1}^n X_i^K$

Ahora solo decimos que $\mu_k = m_k$ y listo.

Recuerda para este paso que $E(X^2) = E(X)^2 + v(X)$

9.3. Método de Máxima Verosimilitud

Ok, este parece que se ve un poco más difícil de explicar pero es igual de sencillo.

Si tenemos una muestra aleatoria de n de una población con una función de probabilidad de $f(x; \theta)$ entonces tenemos que la función de verosimilitud esta dada por:

$$\begin{aligned} L(\theta) &= f(x_1; \theta)f(x_2; \theta) \dots f(x_n; \theta) \\ &= \prod_{i=1}^n f(x_i; \theta) \end{aligned}$$

Ahora lo único que tenemos que hacer es encontrar la θ tal que esta función se maximice.

Ahora, generalmente al esta hablando del producto de funciones lo que se suele hacer es encontrar el máximo de $Ln(L(\theta))$, pues tienen los mismo máximos y es generalmente más sencillos de encontrar.

Ahora, después de derivar con respecto a lo que tu quieras e igualar a cero, lo único que tienes que hacer es despejar lo que tu quieras.

Parte VI

CheatSheet - Formulario

Capítulo 10

CheatSheet - Formulario

10.1. Teoría de Conjuntos

Nombre	Propiedad
Operaciones Básicas	
Complemento	$A' = \{ x \mid x \notin X \}$
Intersección	$A \cap B = \{ x \mid x \in A \text{ y } x \in B \}$
Unión	$A \cup B = \{ x \mid x \in A \text{ ó } x \in B \}$
Leyes de Morgan	
Morgan sobre Unión	$(A \cup B)' = A' \cap B'$
Morgan sobre Intersección	$(A \cap B)' = A' \cup B'$
Combinatoria	
Complemento	$A' = \{ x \mid x \notin X \}$
Intersección	$A \cap B = \{ x \mid x \in A \text{ y } x \in B \}$
Unión	$A \cup B = \{ x \mid x \in A \text{ ó } x \in B \}$

10.2. Combinatoria

- Número de **permutaciones** de un conjunto de n objetos

$$n!$$

- Número de **muestras ordenadas** de tamaño r **con remplazo** de un conjunto de n objetos

$$n^r$$

- Número de **muestras ordenadas** de tamaño r **sin remplazo** de un conjunto de n objetos

$${}_n P_r = \frac{n!}{(n-r)!} = (n)(n-1)(n-2)\dots(n-r+1)$$

- Número de **muestras no ordenadas** de tamaño r **sin remplazo** de un conjunto de n objetos

Esto es lo mismo que el número de subconjuntos de cardinalidad r de un conjunto de n elementos

$$\binom{n}{r} = {}_n C_r = \frac{{}_n P_r}{r!} = \frac{n!}{r!(n-r)!} = \frac{(n)(n-1)(n-2)\dots(n-r+1)}{r!}$$

- Número de subconjuntos de un conjunto de n elementos:

$$2^n$$

item Las formas de permutar n elementos en un círculo es:

$$(n-1)!$$

10.2.1. Propiedades Coeficientes Binomiales

- Propiedades Simétricas

$$\binom{n}{k} = \binom{n}{n-k}$$

- Casos Especiales

$$\binom{n}{0} = \binom{n}{n} = 1 \quad \binom{n}{1} = \binom{n}{n-1} = n$$

- Teorema del Binomio

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

- Teorema del Binomio (Caso Especial)

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

10.3. Probabilidad Básica

Definimos la probabilidad de un evento A como:

$$P(A) = \frac{|A|}{|S|} \quad \text{Recuerda que } A \text{ es un evento y } S \text{ es espacio muestral}$$

10.3.1. Propiedades

- $P(S) = 1$
- Si A_1, A_2, \dots, A_n son eventos mutuamente excluyentes entonces:

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i)$$

- $P(\emptyset) = 0$
- $P(A') = 1 - P(A)$
- Si $A \subseteq B$ entonces $P(A) \leq P(B)$
- La probabilidad de la unión de n eventos de puede escribir de manera general como:

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{i<j} P(A_i A_j) + \sum_{i<j<k} P(A_i A_j A_k) + \dots + (-1)^{n+1} P\left(\bigcap_{i=1}^n A_i\right)$$

- Por consecuencia del caso general tenemos que:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

- Por consecuencia del caso general tenemos que:

$$\begin{aligned} P(A \cup B \cup C) = & P(A) + P(B) + P(C) \\ & - (P(A \cap B) + P(A \cap C) + P(B \cap C)) \\ & + P(A \cap B \cap C) \end{aligned}$$

- $P(A - B) = P(A) - P(A \cap B)$

10.4. Probabilidad Condicional

La probabilidad de que ocurra el Evento A conociendo que ya paso el Evento B se denota y define como:

$$P(A \mid B) := \frac{P(A \cap B)}{P(B)} = \frac{|A \cap B|}{|B|}$$

10.4.1. Propiedades

▪ Conservamos Propiedades

La propiedad condicional cumple las propiedades que ya vimos de una propiedad de un evento cualquiera, pero ahora el espacio muestral que antes era S se ha reducido.

- $P(A \mid B) + P(A' \mid B) = 1$
- $P(A \cup B \mid C) = P(A \mid C) + P(B \mid C) - P(A \cap B \mid C)$

▪ Definición Alternativa

Podemos redefinir a la probabilidad condicional como: $P(A \mid B) = \frac{|A \cap B|}{|B|}$

▪ Regla de Multiplicación

Podemos escribir a $P(A \cap B)$ en terminos de probabilidad condicional.

$$P(A \cap B) = P(A|B) P(B) = P(B|A) P(A)$$

10.5. Eventos Independientes

Dados 2 eventos que A, B son Independientes si y solo si $P(A) = P(A|B)$ y se escribe: $A \perp B$.

10.5.1. Propiedades

- Si $A \perp B$ entonces $P(A \cap B) = P(A)P(B)$
- Si $A \perp B$ entonces $A' \perp B'$
- Si $A \perp B$ entonces $P(A \cap B) \neq 0$
- Si $P(A \cap B) = 0$ entonces A, B no son eventos independientes

10.5.2. Teorema de Bayes

Considera un conjunto de eventos $\{ A_1, \dots, A_n \}$ mutuamente excluyentes y tales que $\bigcup_{i=1}^n A_i = S$, es decir son particiones de S .

Entonces podemos escribir la propabilidad de un evento B donde $B \subset S$ como:

$$P(B) = \sum_{i=1}^n P(B|A_i) P(A_i)$$

Gracias a esto podemos decir que:

$$\begin{aligned} P(A_i|B) &= \frac{P(A_i \cap B)}{P(B)} \\ &= \frac{P(B|A_i) P(A_i)}{\sum_{i=1}^n P(A_i) P(B|A_i)} \end{aligned}$$

10.6. Variables Aleatorias Discretas

10.6.1. Función Probabilidad f_X

Propiedades

Es una función de probabilidad, es decir tiene que cumplir que la suma de todos los posibles valores de la variable aleatoria den uno.

Más formalmente tenemos que la función probabilidad es aquella función que cumple que:

- $\forall a \in \mathbb{R} \quad 0 \leq f_X(a) \leq 1$
- $\{ x \mid f_X(x) \neq 0 \}$ es un conjunto finito o numerable
- $\sum_x f_X(x) = 1$

10.6.2. Función P. Acumulada F_X

Definición

Describimos a la función de probabilidad acumulada como:

$$F_X(x) = \sum_{i \leq x} f_X(i)$$

Propiedades

- Una característica muy común es que:
 - $\lim_{x \rightarrow -\infty} F_X(x) = 0$
 - $\lim_{x \rightarrow \infty} F_X(x) = 1$
- Si $x_1 \leq x_2$ entonces $F_X(x_1) \leq F_X(x_2)$

Función Fundamental

Podemos ver a la acumulada como una función fundamental, tal que podemos escribir a todas las demás:

- $P(X = x) = F_X(x) - F_X(x - 1)$
- $P(X < x) = F_X(x - 1)$
- $P(X \leq x) = F_X(x)$
- $P(X > x) = 1 - F_X(x)$
- $P(X \geq x) = 1 - F_X(x - 1)$
- $P(a \leq X \leq b) = F_X(b) - F_X(a - 1)$
- $P(a < X \leq b) = F_X(b) - F_X(a)$
- $P(a \leq X < b) = F_X(b - 1) - F_X(a)$
- $P(a < X < b) = F_X(b - 1) - F_X(a - 1)$

10.6.3. Esperanza o Media

Definición

Decimos que el valor esperado, esperanza ó media de la variable X se define como:

$$\mu_X = E(X) = \sum_x x f_X(x) = \sum_x x P(X = x)$$

Propiedades

- Si X puede tomar un número infinito de valores entonces la esperanza de X existe si y solo si $\sum_x |x| f_X(x) < \infty$

- Podemos dar una definición al evaluar la esperanza sobre una función:

$$E(g(x)) = \sum_x g(x) f_X(x)$$

- Es un Operador Lineal, es decir:

$$E(\alpha X + \beta Y) = \alpha E(X) + \beta E(Y)$$

- Si X, Y son independientes entonces:

$$E(XY) = E(X)E(Y)$$

- Si a es una constante, entonces:

$$E(a) = a$$

10.6.4. Varianza

Definición

Decimos que la varianza de la variable X con $f_X(x)$ se define como:

$$v(X) = E((X - \mu)^2)$$

Desviación Estandar

Decimos que la desviación estandar de la variable X con $f_X(x)$ se define como:

$$\sigma(X) = \sqrt{v(X)}$$

Se usa generalmente por las unidades que tiene la varianza, nada mas

Propiedades

- $v(X) = E(X^2) - (E(X))^2$
- $V(a) = 0$
- $v(aX) = a^2v(X)$
- $v(X + Y) = v(X) + v(Y) + 2Cov(X, Y)$
- $v(X - Y) = v(X) + v(Y) - 2Cov(X, Y)$
- $v(aX + bY) = a^2v(X) + b^2v(Y) + 2ab Cov(X, Y)$
- Si X y Y son independientes, entonces $v(X + Y) = v(X) + v(Y)$
- En general si X_1, X_2, \dots, X_n son variables aleatorias, entonces tenemos que:

$$v\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n v(X_i) + 2\sum_{i<j}^n Cov(X_i, X_j)$$

10.6.5. Covarianza

Definición

Sea X, Y dos variables independientes, entonces definimos a la covarianza como:

$$\text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y))$$

Es una manera de medir la dispersión conjunta de ambas variables.

Propiedades

- $\text{Cov}(X, Y) = E(XY) - \mu_X\mu_Y$
- La covarianza de 2 variables independientes es cero

10.6.6. Momentos Centrales

Si X es una variable aleatoria tal que $E(X) = \mu_x$ entonces tenemos que:

- El k -ésimo momento central esta definida como:

$$\mu_k^c = E [(X - \mu)^k] = \sum_x (x - \mu)^k P(X = x) \quad (10.1)$$

- El k -ésimo momento alrededor del origen esta definida como:

$$\mu_k^0 = E (X^k) = \sum_x x^k P(X = x) \quad (10.2)$$

Función Generadora de Momentos

La podemos definir como:

$$\Psi_X(t) = E(e^{tX}) = \sum_x e^{tx} P(X = x)$$

Solemos decir que la k-ésima derivada de la función generadora de momentos evaluada en $t = 0$ da como resultado el k-ésimo momento central al origen

Es decir, siguen el siguiente patrón:

- $\Psi'_X(t = 0) = E(X)$
- $\Psi''_X(t = 0) = E(X^2)$
- $\Psi'''_X(t = 0) = E(X^3)$
- $\Psi_X^{(n)}(t = 0) = E(X^n)$

Propiedades

- Nota que $\Psi_x(a) = E(e^{aX})$
- Si $Y = aX + b$ entonces tenemos que:
$$\Psi_Y(t) = e^{bt} \Psi_X(at)$$
- $\Psi_X(t = 0) = \mu_k$
- $\Psi_X(t = 0) = E(X)$
- Nota que si tuvieramos un montón de variables aleatorias $X_1, X_2, X_3, \dots, X_n$ Y decimos que $Y = \sum_{i=1}^n X_i$

Entonces tenemos que:

$$\Psi_Y(t) = \prod_{i=1}^n \Psi_{X_i}(t)$$

10.7. Distribuciones Discretas

10.7.1. Bernoulli

Definición

Suponte un experimento en el que solo tienes dos salidas, 0, 1, 0 para el fracaso y 1 para el éxito, suponte que la probabilidad de que salga 1 es p y la que salga 0 es $q = 1 - p$.

Ahora, nuestra variable aleatoria será:

X : Resultado del experimento

Por lo tanto los valores posibles son $X \sim \{0, 1\}$

Solemos entonces escribir esta distribución como:

$$X \sim \text{Ber}(x; p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito

Función Probabilidad

Esta es clásica:

$$f_X(x) = \begin{cases} q & x = 0 \\ p & x = 1 \end{cases}$$

$$= (p^x)((1-p)^{1-x}) = p^x q^{1-x}$$

Función P. Acumulada

Por definición men:

$$F_X(x) = \begin{cases} 0 & x < 0 \\ q & 0 \leq x < 1 \\ p & 1 \leq x \end{cases}$$

Esperanza

Esta es la distribución con la esperanza más fácil que veras:

$$E(X) = p$$

Varianza

Esta es igualmente sencilla:

$$v(X) = p(1-p) = p - p^2 = pq$$

Función Generadora

Esta igual es muy bonita:

$$\Psi(t) = (q) + e^t(p)$$

10.7.2. Binomial

Definición

Un experimento binomial consiste en n ensayos Bernoulli independientes, con una probabilidad de éxito individual constante e igual en todos los experimentos

La variable aleatoria discreta nos medirá el número de éxitos de los experimentos individuales, donde sus posibles valores fueron $X = \{0, 1, \dots, n\}$.

Observa que la variable aleatoria se puede ver como la suma de Bernoullis independientes, es decir $X = X_1 + X_2 + X_3 + \dots + X_n$

Variable Aleatoria

Ahora, nuestra variable aleatoria sera:

X : Número de Éxitos en los experimentos

Ahora, los valores posibles que puede tomar son muy muy sencillos, suponte que haremos n experimentos, entonces X tiene que tomar valores entre $0 \dots n$

Solemos entonces escribir esta distribución como:

$$X \sim \text{Bin}(x; n, p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito de cada experimento Bernoulli

Función Probabilidad

Esta esta fácil:

$$f_X(x) = \binom{n}{x} p^x q^{n-x}$$

Función P. Acumulada

Esta esta fácil:

$$F_X(x) = \sum_{i=0}^x \binom{n}{i} p^i q^{n-i}$$

Esperanza

Esta también es sencilla:

$$E(X) = np$$

Varianza

Esta es bonita también:

$$v(X) = npq$$

Función Generadora

Por definición tenemos que:

$$\Psi(t) = (q + e^t p)^n$$

Propiedades

- Sean X_1, X_2, \dots, X_k k variables aleatorias discretas independientes y $X_i \sim \text{Bin}(x_i; n_i, p)$ con $i = 1, 2, \dots, k$.

Entonces la variable aleatoria $X = X_1 + X_2 + \dots + X_k$ tiene una distribución binomial tal que $X \sim \text{Bin}\left(x; \sum_{i=1}^k n_i, p\right)$

10.7.3. Geométrica

Definición

Supón que se repiten de manera independiente ensayos Bernoulli con una probabilidad de éxito constante de p hasta obtener el primer éxito.

La variable discreta es el número de experimentos hasta un primer éxito, donde sus posibles valores son $X = \{ 1, 2, 3, \dots \}$.

Variable Aleatoria

Ahora, nuestra variable aleatoria será:

X : Número de experimentos hasta un éxito

Ahora, los valores posibles que puede tomar son muy muy sencillos, porque puede que pase en el primer experimento o en el segundo, es decir la variable aleatoria puede tomar cualquier valor en los enteros positivos.

Solemos entonces escribir esta distribución como:

$$X \sim G(x; p)$$

donde:

- x : Nuestra variable
- p : Probabilidad de Éxito de cada experimento Bernoulli

Función Probabilidad

Esta es fácil:

$$f_X(x) = q^{x-1} p$$

Es decir, es la probabilidad de que todos los anteriores sean fracasos y el actual sea el éxito.

Función P. Acumulada

Esta también es sencilla:

$$F_X(x) = 1 - q^x$$

Esperanza

Esta es muy famosa, y lo repito, que no se te olvide la geométrica

$$E(X) = \frac{1}{p}$$

Varianza

Esta también es sencilla:

$$v(X) = \frac{1-p}{p^2}$$

Función Generadora

Esta también saldrá por definición no somos cobardes:

$$\Psi(t) = \frac{pe^t}{1 - qe^t}$$

Propiedades

- Sea $X \sim G(x; p)$ entonces tenemos que $P(X > a) = q^a$ con a un natural positivo
- Podemos decir que esta distribución no tiene memoria es decir que ya voy a experimentos y no ha pasado nada entonces, debería ya ser más probable que para $a + b$ ya me tocará, me explico mejor ... ¿No? ¡Pues no! Espera, me explico mejor:
Sea $X \sim G(x; p)$ entonces $P(X > a + b \mid X > a) = P(X > b)$ con a, b un naturales positivos

10.7.4. HiperGeométrica

Definición

Supongamos que tenemos una población de tamaño r , ahora esta particionado de 2 maneras, con elementos del tipo r_1 o r_2 , consideraremos exitosos los elementos de tipo r_1

Ahora vamos a tomar una muestra aleatoria de tamaño n sin reemplazo ni sustitución.

Ahora, solo por notación si es que n , es decir la muestra es menor que nuestra población r la llamamos muestra, pero si $n = r$ entonces decimos que es un censo.

Variable Aleatoria

Ahora, nuestra variable aleatoria sera:

X : Número de elementos del tipo r_1 en una muestra aleatoria de tamaño n

Ahora, los valores posibles que puede tomar son $\max(0, n - r_2) \leq x \leq \min(r_1, n)$

Ahora, ¿Porque esos números tan feos?

Por un lado tenemos que que lo peor que nos puede pasar son dos cosas:

- O bien si el tamaño de tu muestra n es muy pequeña, entonces puedes tener toda la mala suerte del mundo y que pase que todas caigan donde tu no querías por lo tanto, podría pasar que no seleccionará ningún elemento de r_1 entonces $X = 0$.
- Pero, pero que pasaría que tu n fuera lo suficientemente grande tal que incluso si seleccionará todos los que no quería r_2 , aún quedarán elementos por seleccionar, entonces los mínimos elementos r_1 que podría seleccionar es $n - r_2$, entonces $X = n - r_2$

El cálculo para el límite mayor es parecido

- Si tienes que $n \leq r_1$, entonces lo mejor que te puede pasar es que todos caigan donde tu quieras
- Si es que $n > r_1$ entonces puedes seleccionar todos los elementos de r_1

Solemos entonces escribir esta distribución como:

$$X \sim H(x; r_1, r_2, n)$$

donde:

- x : Nuestra variable
- r_1 : Tamaño de nuestra población de interes
- r_2 : Tamaño de la población que no es de interes, sale de $r_2 = r - r_1$
- n : Tamaño de la muestra

Función Probabilidad

Esta esta muy interesante, es:

$$f_X(x) = \frac{\binom{r_1}{x} \binom{r_2}{n-x}}{\binom{r}{n}}$$

Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = P(X \leq x) = \frac{1}{\binom{r}{n}} \sum_{i=\max(0, n-r_2)}^x \binom{r_1}{i} \binom{r_2}{n-i}$$

Esperanza

Esta esta muy interesante:

$$E(X) = n \left(\frac{r_1}{r} \right)$$

Varianza

Esta esta muy difícil, así que se deja para el lector :p

$$v(X) = n \left(\frac{r_1}{r} \right) \left(1 - \frac{r_1}{r} \right) \left(1 - \frac{n-1}{r-1} \right)$$

Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = E(e^{tX}) = \frac{1}{\binom{r}{n}} \sum_{i=\max(0, n-r_2)}^{\min(n, r_1)} e^{ti} \binom{r_1}{i} \binom{r_2}{n-i}$$

Relación con la Binomial

Suponte que tienes una población de r elementos, con r_1 de un tipo “bueno” y $r_2 := n - r$ de un tipo “malo”.

Ahora vamos a tomar una muestra aleatoria de tamaño n , sea entonces X : Número de elementos de tipo bueno en nuestra muestra

ahora podemos tener entonces 2 posibles distribuciones dependiendo de una pregunta clave.

¿Hay reemplazo?

- **Si es que tiene Reemplazo:**

Entonces lo que pasa es que la probabilidad de éxito es constante, por lo tanto es simplemente n experimentos de tipo Bernoulli.

La probabilidad de éxito también es bastante sencilla de sacarse, es como $p = \frac{r_1}{r}$

Por lo tanto podemos decir que:

$$X \sim B(x; n, p)$$

Es decir, tendremos (como ya sabemos como se comporta una binomial):

- $E(X) = np = \frac{nr_1}{r}$
- $v(X) = npq = \frac{nr_1}{r} \left(1 - \frac{r_1}{r}\right)$

- **Si es que NO tiene Reemplazo:**

Entonces lo que pasa es que la probabilidad de éxito ya no es constante, de hecho, llegamos a la definición de la Hipergeométrica, es decir:

Por lo tanto podemos decir que:

$$X \sim H(x; n, r_1, r_2)$$

Es decir, tendremos (como ya sabemos como se comporta una hipergeométrica):

- $E(X) = np = \frac{nr_1}{r}$
- $v(X) = npq = \frac{nr_1}{r} \left(1 - \frac{r_1}{r}\right) \left(1 - \frac{n-1}{r-1}\right)$

Es decir, sin importar si hay o no reemplazo, el valor esperado es el mismo, pero si es que no hay reemplazos tenemos una varianza es menor.

Podemos también darnos cuenta de que mientras más población la diferencia entre el reemplazo y sin reemplazo cada vez será menor.

10.7.5. Poisson

Variable Aleatoria

La variable aleatoria que cuenta el número de ocurrencias en un periodo de tiempo o espacio físico dado se le llama Poisson.

X : Número de ocurrencias en un periodo de tiempo o espacio dado

Ahora, los valores posibles que puede tomar es $0, 1, 2, \dots$

Solemos entonces escribir esta distribución como:

$$X \sim P(x; \lambda)$$

donde:

- x : Nuestra variable
- λ : Es el número promedio de ocurrencias en el periodo o espacio dado

Relación con la Binomial

Considera $X \sim Bin(x; n, p)$, entonces cuando más grande sea n más nuestra binomial se va a parecer a una Poisson con $\lambda = np$

Propiedades

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim P(x_i; \lambda_i)$
Entonces $X = \sum_{i=1}^k X_i$ cumple que X se distribuye como una Poisson con parámetro $\lambda = \sum_{i=1}^k \lambda_i$

Función Probabilidad

Esta esta muy interesante, es:

$$f_X(x) = P(X = x) = e^{-\lambda} \frac{\lambda^x}{x!}$$

Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = P(X \leq x) = e^{-\lambda} \sum_{i=0}^x \frac{\lambda^i}{i!}$$

Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = e^{\lambda(e^t - 1)}$$

Esperanza

Esta esta muy interesante:

$$E(X) = \lambda$$

Varianza

Esta esta muy interesante:

$$v(X) = \lambda$$

10.8. Distribuciones Continuas

10.8.1. Uniforme

Definición

La mas sencilla de todas las distribuciones continuas es la uniforme.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $a < x < b$.

Solemos entonces escribir esta distribución como:

$$X \sim U(x; a, b)$$

donde:

- a : Inicio de la muestra
- b : Fin de la muestra

Función Probabilidad

Esto es lo que distingue a una distribución uniforme:

$$f_X(x) = \begin{cases} \frac{1}{b-a} & a < x < b \\ 0 & \text{en otro caso} \end{cases}$$

Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = \frac{x-a}{b-a}$$

Esperanza

Esta esta muy interesante:

$$E(X) = \frac{a+b}{2}$$

Varianza

Esta esta muy difícil, pero si se puede:

$$v(X) = \frac{(a-b)^2}{12}$$

Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = \frac{e^{bt} - e^{at}}{t(b-a)}$$

10.8.2. Exponencial

Definición

Se utiliza generalmente para representar una distribución del tiempo que transcurre antes de la ocurrencia de un suceso.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $x > 0$

Solemos entonces escribir esta distribución como:

$$X \sim E(x; \beta)$$

donde:

- β : Es un parámetro que tiene que ser un entero positivo

Función Probabilidad

Esto es lo que distingue a una distribución exponencial:

$$f_X(x) = \begin{cases} \beta e^{-\beta x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

Función P. Acumulada

Esta esta muy interesante, es:

$$F_X(x) = 1 - e^{-\beta x}$$

Función Generadora

Esta esta muy interesante, es:

$$\Psi_X(t) = \frac{\beta}{\beta - t}$$

Esperanza

Esta esta muy interesante:

$$E(X) = \frac{1}{\beta}$$

Varianza

Esta esta muy difícil, pero si se puede:

$$v(X) = \frac{1}{\beta^2}$$

Propiedades

- Podemos decir que esta distribución no tiene memoria, me explico mejor.
Sea $P(X > a + b \mid X > a) = P(X > b)$ con a, b un naturales positivos
- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim E(x_i; \beta)$
Entonces $X = \min(X_1, X_2, \dots, X_k)$ también cumple que X se distribuye como una Exponencial con parámetro $\beta = n\beta$
- Sea $X_1, X_2, \dots, X_\alpha$ variables aleatorias independientes y $X_i \sim E(x_i; \beta)$
Entonces $X = X_1 + X_2 + \dots + X_\alpha$ se distribuye como como $X \sim \Gamma(x; \alpha, \beta)$

10.8.3. Gamma

Función Gamma

La función Gamma se puede ver para $a > 0$ como:

$$\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx$$

Propiedades

La función gamma tiene un par de propiedades interesantes

- $\Gamma(1) = 1$
- $\Gamma(a) = (a-1)\Gamma(a-1)$
- Si $n \in \mathbb{Z}^+$ entonces $\Gamma(n) = (n-1)!$

Definición

Se utiliza generalmente para representar una distribución del tiempo que transcurre antes de la ocurrencia de un suceso.

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria es $x > 0$

Solemos entonces escribir esta distribución como:

$$X \sim \Gamma(x; a, \beta)$$

donde:

- a : Entero positivo
- β : Es un parámetro que tiene que ser un entero positivo

Función Probabilidad

Esto es lo que distingue a una distribución uniforme:

$$f_X(x) = \begin{cases} \frac{\beta^a}{\Gamma(a)} x^{a-1} e^{-\beta x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

Función Acumulada

Esta esta rara, pero ve que.

$$F_X(x) = 1 - F_X^P(\alpha - 1) \quad \text{Con } \lambda = \beta x$$

Es decir:

$$F_X(x) = 1 - e^{-\beta x} \sum_{i=0}^{\alpha-1} \frac{(\beta x)^i}{i!}$$

Generadora de Momentos

Esto es lo que distingue a una distribución uniforme:

$$\Psi_X(t) = \left(\frac{\beta}{\beta - t} \right)^\alpha$$

Esperanza

Usando la función generadora tenemos que:

$$E(X) = \frac{\alpha}{\beta}$$

Varianza

Usando la función generadora tenemos que:

$$v(X) = \frac{\alpha}{\beta^2}$$

Propiedades

- Si tenemos una distribución Gamma pero donde $\alpha = 1$, entonces lo que en realidad tenemos es una distribución exponencial con la misma β
- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim \Gamma(x_i; \alpha_i, \beta)$
Entonces $X = X_1 + X_2 + \dots + X_k$ se distribuye como como $X \sim \Gamma(x; \sum_{i=1}^k \alpha_i, \beta)$

10.8.4. Normal

Definición

Es la más famosa de todas las continuas, es simétrica con respecto al valor central μ

Variable Aleatoria

Ahora, los valores posibles que puede tomar nuestra variable aleatoria son todos los reales

Solemos entonces escribir esta distribución como:

$$X \sim N(x; \mu, \sigma^2)$$

donde:

- μ : El valor central, es cualquier real
- σ^2 : La varianza, es un real positivo

Nota que si pasa que $X \sim N(x; \mu = 0, \sigma^2 = 1)$ entonces se suele denotar como:

$$Z \sim N(0, 1)$$

Se le conoce como normal estandar.

Estandarización

Ya que tenemos una normal estandar, es decir una que cumple que $\mu = 0, \sigma^2 = 1$

Ahora, hay una forma muy fácil de “estandarizar” es decir de transformar cualquier punto sobre una normal a ese punto en la estandar esta esta dada por:

$$Z = \frac{X - \mu}{\sigma}$$

Y obviamente tiene su inversa:

$$X = Z\sigma + \mu$$

Función Probabilidad

Esto es lo que distingue a una distribución uniforme:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

Generadora de Momentos

Esta es sencilla:

$$\Psi_X(t) = e^{t\mu + \frac{1}{2}(t^2\sigma^2)}$$

Media

Mira, que loco :v

$$E(X) = \mu$$

Varianza

Mira, que loco :v

$$v(X) = \sigma^2$$

Propiedades

- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim N(x_i; \mu_i, \sigma_i^2)$
Entonces $X = X_1 + X_2 + \dots + X_k$ se distribuye como como $X \sim N(x_i; \sum_{i=1}^k \mu_i, \sum_{i=1}^k \sigma_i^2)$
- Sea $X_i \sim N(x_i; \mu, \sigma^2)$
Entonces $Y = aX + b$ se distribuye como como $Y \sim N(y; a\mu + b, a\sigma^2)$
- Sea X_1, X_2, \dots, X_k variables aleatorias independientes y $X_i \sim N(x_i; \mu, \sigma^2)$
Entonces $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ se distribuye como como $\bar{X} \sim N(\bar{x}; \mu, \frac{\sigma^2}{n})$

10.9. Probabilidad Hardcore

Teorema Central del Límite

$$\sum_{i=0}^n X_i \approx N(x; \mu_x = n\mu, \sigma_x^2 = n\sigma^2)$$

10.9.1. Definición

Garantiza que para n (tamaño de muestra) suficientemente grande ($n \geq 30$) entonces:

- Si tienes una variable aleatoria que es la media muestral de otras variables aleatorias entonces mientras más variables aleatorias muestrees entonces más se va aproximar:

$$\bar{X} \approx N(x; \mu = \mu, \sigma^2 = \frac{\sigma^2}{n})$$

- Si tienes una variable aleatoria que esta compuesta por la suma de muchas otras variables aleatorias entonces mientras más grande sea la cantidad de variables aleatorias más se aproxima a una normal:

Teorema Central de Chebyshev

Definición

Si no se conoce la distribución de la variable aleatoria, pero por circunstancias raras tengamos la media y la varianza entonces podemos conocer información de la variable.

Tenemos que:

$$P(\mu - k\sigma \leq X \leq \mu + k\sigma) \geq 1 - \frac{1}{k^2}$$

$$P(|X - \mu| \leq k\sigma) \geq 1 - \frac{1}{k^2}$$

$$P(|X - \mu| > k\sigma) < \frac{1}{k^2}$$

Bibliografía

- [1] Leticia Cañedo Suárez *Probabilidad*. ESCOM, 2018