

FRANCISCO MONTES SUAY

PROBABILIDAD

UNIVERSITAT DE VALÈNCIA

Índice general

1	El concepto de Probabilidad	5
2	Probabilidad y medida	15
3	Aplicaciones medibles. Variables aleatorias	25
4	Variables aleatorias discretas	33
5	Variables aleatorias continuas	45
6	Vectores aleatorios	57
7	Esperanza matemática o valor esperado	67
8	Esperanza y momentos de un vector aleatorio	83
9	Algunos teoremas de convergencia	93
10	Función característica	95
11	Independencia	107

Capítulo 1

El concepto de Probabilidad

EL CONCEPTO DE PROBABILIDAD

(1)

SUCESOS CIERTO, IMPOSIBLE Y ALEATORIO. - Sobre la base de la observación y la experimentación

los científicos enuncian leyes que explican y gobiernan los fenómenos bajo estudio. La más elemental y general de estas leyes podrá enunciarse de la siguiente manera:

1. En cada realización de un conjunto de condiciones G ocurre el suceso A .

Respecto, para estudiar esta afirmación general supongamos calentamos a 100°C y a la presión atmosférica, 760 mm (conjunto de condiciones G), agua, el resultado será que dicha agua líquida formará en vapor (suceso A). Análogamente, para cualquier reacción química de sustancias, con intercambio con el medio que le rodea (condiciones G), la cantidad total de materia permanece constante (suceso A). Esta afirmación es conocida como la ley de conservación de la materia. Fenómenos como los citados son abundantemente conocidos en Química, Física, Biología y otras ciencias experimentales.

Los sucesos que resultan de la realización de determinado conjunto de condiciones pueden agruparse en tres tipos:

- a) Aquellos sucesos que inevitablemente ocurren para cada realización del conjunto de condiciones G y que se denominan sucesos ciertos o seguros.
- b) Si A no puede ocurrir cuando se realizan las condiciones G , se dice que A es un suceso imposible, finalmente.
- c) Si, validando las condiciones G , A puede o no puede ocurrir, se dice entonces que A es un suceso aleatorio.

** Obsérvese que de estas definiciones los conceptos de certeza, imposibilidad y aleatoriedad están siempre referidos a un conjunto definido de condiciones G .

La afirmación de aleatoriedad para un suceso A aporta muy poca información para el conocimiento del suceso, establece simplemente que el conjunto de condiciones G no refleja la colección entera de causas necesarias y suficientes para la realización de A . En nuestro interés por conocer más acerca de este tipo de sucesos, observamos que existen una gran cantidad de fenómenos en los que, dada una serie de repeticiones de las realidades de las condiciones G , la proporción de ocurrencias de A no ocasionalmente se desvía de forma significativa de un cierto valor medio, valor que puede servirnos para caracterizar de alguna manera al suceso examinado. Para este tipo de fenómenos podemos, no sólo establecer su aleatoriedad, sino estimar cuantitativamente la probabilidad de su ocurrencia. Esta estimación podemos expresarla mediante una proporción del tipo:

2. La probabilidad de que un suceso A ocurra durante la realización de un conjunto de condiciones G es igual a p .

Regularidades de este tipo son conocidas como probabilísticas o estocásticas y juegan un importante papel en diversos campos de la ciencia. Por ejemplo, no hay forma de predecir si un determinado átomo de radio se desintegrará o no en un periodo de tiempo dado, pero sí

podrá, sobre la base de experimentos de ajuste, determinar la probabilidad de tal desintegración y decir: un átomo de radio se desintegrará en un intervalo de tiempo de t años con una probabilidad

$$p = 1 - e^{-0.000436t}$$

El conjunto de condiciones G consiste, aquí, en el hecho de considerar un átomo de radio, durante un periodo de t años, no sujeto a ninguna acción externa intencional (como bombardeo con partículas de alta velocidad, por ejemplo), (valequiera otras condiciones de existencia que intervengan en el caso que nos ocupa (presión, temperatura, etc.)). El suceso A consiste en el hecho de que el átomo se desintegre en un periodo dado de t años.

La idea que para ahora muy natural, de que la probabilidad de un suceso aleatorio A , bajo condiciones dadas, admite una cuantificación mediante algún número $p = P(A)$ fue elaborada de manera sistemática por primera vez en el siglo 17 en los trabajos de Fermat (1601-1665), Pascal (1623-1662), Huygens (1629-1695) y en particular por Jacobo Bernoulli (1654-1705). Sus investigaciones ~~abrieron~~ colocaron los fundamentos de la teoría de la probabilidad. Desde aquel tiempo, esta teoría ha estado desarrollándose como una disciplina matemática y ha sido enriquecida con importantes resultados. Su aplicación al estudio de fenómenos reales de la más diversa naturaleza continúa creando nuevas e importantes informaciones.

No existe ninguna duda en cuanto a que el concepto de probabilidad matemática computa importantes florituras que justifican su estudio desde esta perspectiva. El problema básico, desde la perspectiva filosófica, radica en el siguiente: ¿bajo qué condiciones existe significación objetiva en la estimación cuantitativa de la probabilidad de un suceso aleatorio A con la ayuda de un número fijo $P(A)$, llamado probabilidad matemática del suceso A , y cuál es la significación objetiva de esta estimación?

Cada investigador que aplica la teoría de la probabilidad a su área específica, procede realmente con la convicción de que los juicios probabilísticos expresan ciertas propiedades objetivas del fenómeno bajo estudio. Afirmando que bajo ciertas condiciones G la ocurrencia del suceso A tiene una probabilidad p es afirmar que entre el conjunto de condiciones G y el suceso existe una cierta relación perfectamente definida, aunque peculiar y no por ello menos objetiva, relación que es independiente del investigador. El problema es determinar la naturaleza de esta relación. La dificultad de intentar a este último interrogante los hechos puede la circunstancia paradójica de que algunos científicos hayan afirmado que los juicios probabilísticos dependen sólo del estado del investigador. Hay que señalar, que si bien esto no es así, la experiencia demuestra que el significado objetivo de la probabilidad matemática tiene sentido en el contexto de un conjunto de condiciones perfectamente definido.

En cualquier caso cuestiones de este tipo no deben ser objeto de estudio en un curso como el presente y nos ocuparemos tan sólo de los aspectos matemáticos del problema al manejar la determinación de la naturaleza del concepto.

(2)

DIFERENTES APROXIMACIONES A LA DEFINICIÓN DE PROBABILIDAD

(3)

Un gran número de definiciones de la probabilidad matemática han sido propuestas por diferentes autores. No nos ocuparemos aquí de todas ellas. Hay que resaltar que el interés por una definición lógicamente inaprovechable del concepto de probabilidad surgió más tarde, históricamente hablando, que la capacidad para determinar la probabilidad de los sucesos, para llevar a cabo cálculos con estas probabilidades y también para utilizar los resultados de estos cálculos en ciertos predicciones que investigación científica. Por esta razón, en gran parte de los intentos por establecer una definición científica del concepto general de probabilidad se ha buscado por varios aspectos del proceso de conocimiento científico que en cada caso específico conduce a una determinación real de la probabilidad de un suceso dado, ya se trate de la probabilidad de obtener un seis en cuatro lanzamientos de un dado o la probabilidad de desintegración de un átomo de una materia radiactiva.

En la gran mayoría de las definiciones podemos establecer los tipos siguientes:

- 1.- Definiciones de la probabilidad matemática como una medida cuantitativa del grado de certeza del observador.
- 2.- Definiciones que reducen el concepto al de igual probabilidad, al más primitivo de todos (se lo conoce como definiciones clásicas).
- 3.- Definiciones que proceden a partir de la frecuencia de ocurrencia de un suceso en un elevado número de pruebas (definiciones estadísticas).

Al ocuparnos de las del tipo 2 y 3 no sin antes criticar las definiciones agrupadas en el tipo 1. En efecto, el hecho de admitir la existencia de la realidad al margen de nosotros y del movimiento que de ella tenemos y tener en cuenta el éxito de los juicios probabilísticos en el conocimiento y aprendizaje del mundo exterior, ^{debería} significativamente daría que las definiciones puramente subjetivas de la probabilidad matemática son totalmente insostenibles. El problema es que en el lenguaje ordinario las expresiones "probablemente", "muy probablemente", "es altamente improbable", etc. expresan simplemente la actitud del que habla respecto de la verdad o la falsedad de algún juicio simple, en contra de otras interpretaciones que justificarían definiciones subjetivas como las del tipo 1. Debemos por tanto poner el énfasis en una circunstancia que todavía no ha sido señalada: mientras entonces las aplicaciones científicas de la teoría de la probabilidad, "probabilidad" es la probabilidad de la ocurrencia de algún suceso A, cuando un determinado conjunto de condiciones G, que es fundamentalmente reproducible un infinito número de veces, ha sido valorado (y solo en la interpretación que la afirmación $p = P(A)$ expresa una cierta regularidad con significado objetivo), en el habla ordinaria se acostumbra hablar de una mayor o menor probabilidad de algún juicio muy definido. Veamos un ejemplo a través de los dos juicios siguientes:

- a) Cualquier número natural, por, mayor que 2 puede ser representado mediante la suma de dos números primos ($4=2+2$, $6=3+3$, $8=5+3$, ...)
- b) Nevó en Valencia el 3 de febrero de 1982.

(4)

Respecto de la afirmación hecha en a) es bien notorio que un matemático que plete muchos se verían a menudo como extremadamente probable, en cuanto a la afirmación hecha en b) habrá que esperar al 3 de febrero de 1982 para tener una respuesta exacta. Sin embargo, dado que no suele nevar en Valencia nunca, esta afirmación será considerada altamente improbable. El concepto de probabilidad utilizado en el análisis de estos dos juicios notiene nada que ver con el correspondiente concepto matemático. En ambos casos se trata de reflejar la actitud del que habla respecto de la cuestión planteada, actitud que tendrá su inspiración o inspiración cuando a) sea probado o en el caso de b) el día 2 de febrero de 1982 y por tanto carecerá de sentido pretender estimar su probabilidad matemática ahora porque, insistimos, se trata de hechos aislados (afirmación b)) o juicios específicos (afirmación a)).

ESPACIO MUESTRAL

Antes de ocuparnos en primer lugar y de manera exhaustiva de la definición clásica de probabilidad, de su utilidad para resolver determinado tipo de problemas en unas condiciones que de su momento discutiremos. Antes a los hemos de introducir una serie de conceptos preliminares que nos serán útiles posteriormente.

Consideremos un conjunto fijo de condiciones G y una familia S de sucesos A, B, C, ... que pueden ocurrir o no cuando se realiza G. Existen entre los elementos de S ciertas relaciones de interrelación que vamos a poner de manifiesto.

- 1.- Si para cada realización del conjunto de condiciones G en la que ocurre el suceso A, ocurre también el suceso B, decimos que A implica B y lo demostramos mediante $A \subset B$ o $B \supset A$.
- 2.- El hecho de que A y B se impliquen mutuamente supone que ambos sucesos son equivalentes, lo que denotamos mediante $A = B$. Hemos de señalar que por lo que respecta a la teoría de la probabilidad, los sucesos equivalentes pueden reemplazarse uno por otro y por tanto en adelante los consideraremos simplemente como coextensos.
- 3.- Un suceso que consiste en la ocurrencia simultánea de dos de los A y B se llamará producto de A y B y lo denotaremos AB (o $A \cap B$).
- 4.- Un suceso que consiste en la ocurrencia de al menos uno de los sucesos A y B se llamará suma de A y B (su representación es $A+B$ (o $A \cup B$)).
- 5.- Un suceso que consiste en el hecho de que ocurra A pero no B se llama diferencia

de A y B y designa mediante $A \cdot B$.

⑤

Introducimos mediante un ejemplo otros nuevos conceptos. Supongamos que G consiste en el hecho de lanzar un dado una vez. Sea A obtener un seis en el lanzamiento, B obtener un tres, C obtener un número par de puntos y D obtener un múltiplo de 3. Los sucesos A, B, C y D están relacionados de la siguiente manera

$$A \subset C, A \subset D, B \subset D$$

$$A + B = D, CD = A$$

La definición de suma y producto de dos sucesos puede generalizarse a un número finito de sucesos mediante

$$A + B + \dots + N \quad (A \cup B \cup \dots \cup N)$$

que significa un suceso que consiste en la ocurrencia de al menos uno de los sucesos $A, B, \dots, N$. Análogamente

$$AB \dots N \quad (A \cap B \cap \dots \cap N)$$

significa un suceso consistente en la ocurrencia de todos los sucesos $A, B, \dots, N$.

6.- Un suceso se llama certo si ocurre necesariamente al realizar G . Por ejemplo al lanzar dos dados la suma de sus caras es ciertamente mayor o igual a 2. Cuando el suceso no ocurre bajo las condiciones utilizadas, se le llama suceso imposible. Por ejemplo obtener 13 puntos en el lanzamiento de los dos dados.

Como todos los sucesos ciertos e imposibles son equivalentes entre sí se acostumbra designarlos genéricamente mediante las letras Ω y ϕ respectivamente (o cualquier otras, pero siempre la misma para todos ellos).

7.- Dos sucesos A y $\bar{A}$ se llaman contrarios si se verifican mutuamente excluyéndose las relaciones

$$A + \bar{A} = \Omega \quad \text{y} \quad A\bar{A} = \phi$$

Por ejemplo, si A representa obtener un número par de puntos al lanzar un dado, entonces

$$\bar{A} = \Omega - A \quad \text{representa obtener una suma impar de puntos.}$$

8.- Dos sucesos A y B se dice que son mutuamente excluyentes o incompatibles si no pueden ocurrir simultáneamente, es decir, si

$$AB = \phi$$

Si

$$A = A_1 + A_2 + \dots + A_n$$

con los A_i incompatibles entre sí, es decir, $A_i A_j = \phi$, $i \neq j$, decimos que A puede descomponerse en sucesos particulares $A_1, \dots, A_n$, o simplemente que los A_i son particiones de A . Por ejemplo, si A es el número par de puntos y C_2, C_4, C_6 representan obtener 2, 4 o 6 en el lanzamiento respectivamente,

entonces $A = C_2 + C_4 + C_6$ y además son incompatibles entre sí. ⑥

Los sucesos $B_1, B_2, \dots, B_n$ forman un grupo completo de sucesos si al menos uno de ellos ocurre en la realización de G . Es decir

$$B_1 + B_2 + \dots + B_n = \Omega.$$

Especialmente interesantes son los grupos completos de sucesos incompatibles los cuales también llamados particiones.

9.- Cualquier problema en teoría de la probabilidad supone la existencia de un conjunto de indiciales G y de una familia de sucesos S que ocurren o no cuando se realizan las indiciales de G . La experiencia demuestra que es aconsejable hacer las siguientes suposiciones respecto del sistema sueto:

a) Si la familia S incluye los sucesos A y B incluye también los sucesos $AB, A+B, A-B$.

b) La familia S contiene al suceso cierto e imposible.

Una familia de sucesos que satisfaga estas condiciones se denomina álgebra de sucesos.

Observamos que en los ejemplos utilizados como ilustración, siempre se puede señalar sucesos que no admiten esas suposiciones en otros más simples: obtener un determinado número de puntos, entre 1 y 6 al lanzar un dado, obtener cara o cruz al lanzar una moneda, etc. A este tipo de sucesos que no admiten esas suposiciones se les llaman sucesos simples o elementales.

En la construcción de una teoría matemática de las probabilidades parece necesaria una formalización mayor de la llevada a cabo en los párrafos precedentes. En las expresiones modernas de la teoría de la probabilidad el punto de partida es un conjunto de sucesos elementales al que denominamos espacio de sucesos simples o espacio muestral. La naturaleza de los elementos de dicho espacio no se especifica de antemano de manera que permita la suficiente libertad de elección como para abarcar todos los fenómenos posibles. Para los subconjuntos del espacio muestral se le conoce como sucesos descriptivos. Un suceso consistente en todos los puntos del espacio muestral se conoce como el suceso cierto o evento. Todas las relaciones descriptivas anteriormente entre los sucesos se verifican también cuando llevamos a cabo una construcción formal de la teoría. De los momentos subsiguientes sobre el tema para volver a cabo de forma exhaustiva dicha construcción. Por ahora continuaremos con la situación existente en los párrafos anteriores y en particular, para la definición clásica del concepto de probabilidad, tendremos en cuenta tan solo los espacios muestrales con un número finito de elementos.

Expresamos formalmente que entre los sucesos y las relaciones establecidas cumplen los siguientes

leyes que enunciaremos sin demostración:

Ley Conmutativa: $A + B = B + A, AB = BA$

Ley Asociativa: $A + (B + C) = (A + B) + C, A(BC) = (AB)C$

Ley Distributiva: $A(B + C) = AB + AC, A + (BC) = (A + B)(A + C)$

Ley Idempotente: $A + A = A, AA = A$

LA DEFINICION CLASICA DE PROBABILIDAD

(7)

la definición clásica de probabilidad reduce el concepto de probabilidad a la noción de equiprobabilidad entre los sucesos elementales, noción que se considera básica y no está sujeta a definición formal.

Sea Ω un conjunto de n sucesos elementales todos ellos con igual probabilidad de ocurrir,

$$\Omega = \{E_1, \dots, E_n\}.$$

Designemos por $\mathcal{S}$ la familia formada por Ω , el suceso cierto, ϕ , el suceso imposible, los E_k , $k=1, \dots, n$ y cualquier otro suceso A que admita una descomposición en elementos de Ω .

Por ejemplo, si $\Omega = \{E_1, E_2, E_3\}$, entonces $\mathcal{S} = \{\Omega, E_1, E_2, E_3, E_1+E_2, E_1+E_3, E_2+E_3, \phi\}$.

Se comprueba fácilmente que la familia $\mathcal{S}$ constituye una álgebra de sucesos. La definición clásica de probabilidad puede formularse como sigue:

Definición: Si A , un suceso de $\mathcal{S}$, está compuesto por m de los sucesos elementales que componen Ω , entonces la probabilidad del suceso A es

$$P(A) = \frac{m}{n}.$$

Esta fórmula conocida con el nombre de fórmula de Laplace por su autor científico quien la formuló por primera vez en el siglo XVIII. Se encuentra también en ocasiones diciendo que "la probabilidad de un suceso A es el cociente entre el número de resultados del experimento favorables a la realización del mismo y el número de resultados posibles".

Ejemplo: Supongamos que lanzamos un dado, el espacio muestral estará formado por $\Omega = \{E_1, \dots, E_6\}$ donde E_i representa el hecho de que haya aparecido una cara con i puntos. Definimos

$$G = E_2 + E_4 + E_6$$

que es un suceso que representa el hecho de que haya aparecido un número de puntos par en la cara, de acuerdo con la definición dada

$$P(G) = \frac{3}{6} = \frac{1}{2}.$$

Para cada uno de los sucesos elementales y siempre de acuerdo con la definición $P(E_i) = \frac{1}{6}$, $i=1, \dots, 6$

Volvamos nuevamente a la definición de probabilidad que acabamos de dar. Observamos que $P(A)$ puede considerarse como una función definida sobre el álgebra de conjuntos, más exactamente como una función de conjunto definida sobre el álgebra $\mathcal{S}$ de los sucesos. Como tal función y a la luz de su definición puede las siguientes propiedades:

Propiedades de la probabilidad

$$1) \forall A \in \mathcal{S} \quad P(A) \geq 0$$

$$2) \text{ Para el suceso cierto, } \Omega, \quad P(\Omega) = 1$$

$$3) \text{ Si } A \text{ puede descomponerse de la forma } A = B + C, \text{ con } B \cap C = \phi, \text{ entonces} \quad P(A) = P(B) + P(C).$$

$$4) \text{ La probabilidad de } \bar{A}, \text{ el suceso contrario de } A, \text{ viene dada por} \quad P(\bar{A}) = 1 - P(A).$$

$$5) \text{ La probabilidad del suceso imposible, } \phi, \text{ es cero.}$$

$$6) \text{ Si un suceso } A \text{ implica un suceso } B, \text{ entonces} \quad P(A) \leq P(B).$$

$$7) \text{ La probabilidad de cualquier suceso está comprendida entre } 0 \text{ y } 1, \text{ es decir} \quad 0 \leq P(A) \leq 1, \quad \forall A \in \mathcal{S}.$$

Las demostraciones de estas propiedades son sencillas y puede hacerse uno ejercicio.

EJEMPLOS DE APLICACION DE LA DEFINICION CLASICA DE PROBABILIDAD

Consideremos a continuación algunos casos en los que el cálculo de las correspondientes probabilidades puede llevarse a cabo mediante la utilización de la definición estudiada, por cuanto las condiciones del problema satisfacen las condiciones exigidas en aquella. Los supusimos basados en algunos resultados de combinatoria que son interesantes y útiles para la resolución de este tipo de problemas.

EJEMPLO 1: De una baraja de 36 cartas se extraen 3 al azar. Encuentra la probabilidad de que haya exactamente un as entre ellas.

El espacio muestral, todos los posibles extrajes de 3 cartas, está formado por $\binom{36}{3}$ puntos y además todos ellos son igualmente posibles. El número de estos extrajes que contienen un solo as puede determinarse de la siguiente manera: uno de los ases ha de ser un as y podrá ser uno de los cuatro, podrá ser elegido de (4) maneras distintas. Los otros dos cartas deberán elegirse ~~al azar~~ al azar entre las 32 cartas restantes del mazo y esto podrá hacerse de $\binom{32}{2}$ maneras, es definitiva los casos favorables serán $(4) \cdot \binom{32}{2}$ y la probabilidad del suceso A , hay un as entre las tres extraídas, será

$$P(A) = \frac{(4) \cdot \binom{32}{2}}{\binom{36}{3}} = \frac{496}{1785} \approx 0.2778.$$

EJEMPLO 2: De una baraja de 36 cartas se extraen 3 al azar. Probabilidad de que haya al menos un as entre ellas.

Sea A el suceso que nos interesa. Este suceso puede descomponerse en tres incompatibles entre sí, a saber, A_1 hay un solo as en las tres cartas extraídas, A_2 hay 2 ases en las cartas extraídas y A_3 los tres ases. De acuerdo con una propiedad de la probabilidad tendremos

$$P(A) = P(A_1) + P(A_2) + P(A_3).$$

(8)

Razonando como en el ejemplo anterior tendremos

$$P(A_i) = \frac{\binom{4}{i} \cdot \binom{32}{3-i}}{\binom{36}{3}}, \quad i=1,2,3.$$

Y de aquí

$$P(A) = \frac{109}{3119} \approx 0.3503.$$

Puede resolverse este problema de otra forma. En efecto, podemos calcular la probabilidad de $\bar{A}$, suceso que representa el hecho de que no ha ningún as entre los cartas extraídas, los casos favorables se obtienen eliminando los 4 ases del mazo y eligiendo las tres cartas entre las 32 cartas restantes, de aquí

$$P(\bar{A}) = \frac{\binom{32}{3}}{\binom{36}{3}} = \frac{31.8}{31.77} \approx 0.6947$$

$$\text{Y de aquí } P(A) = 1 - P(\bar{A}) \approx 1 - 0.6947 \approx 0.3053.$$

Estos dos ejemplos ponen de manifiesto la utilidad de la combinatoria en la solución de este tipo de problemas. Vamos a dar a continuación algunos resultados de combinatoria que resultan de gran ayuda.

Algunos resultados de combinatoria.

El primero de estos resultados, que se conoce en alemán con el nombre del principio fundamental del conteo, es de demostración inmediata y afirma:

Teorema 1.- Sea T un trabajo o tarea que requiere, para llevarse a cabo, de la presencia de k trabajos, $T_i, i=1, \dots, k$, de manera que cada uno de ellos puede utilizarse de $n_i, i=1, \dots, k$ formas distintas. Entonces, el número de formas distintas de ejecutar T viene dado por $\prod_{i=1}^k n_i$.

A continuación vamos a considerar problemas de seleccionar bolas de una urna o de colocar bolas en celdas, problemas que sirven como modelos generales para gran número de problemas de la vida real. En todos ellos se aplicará implícita o explícitamente el principio fundamental que acabamos de enunciar.

Consideremos una urna con n bolas numeradas, blancas, rojas, etcétera. Si extraemos k bolas de la urna, diremos que hemos extraído una muestra de tamaño k . La muestra diremos que es ordenada si el orden en que las bolas fueron extraídas, estando en cuenta, en cualquier otro caso diremos que la muestra es desordenada. Hemos el siguiente resultado.

Teorema 2.- El número de muestras de tamaño k , ordenadas, es el número de variaciones de n elementos tomados de k en k , $V_{n,k} = n(n-1) \dots (n-k+1)$, si las extracciones han sido hechas con reposición y es igual a n^k si las extracciones se llevan a cabo con reposición.

Para muestras desordenadas dichos números son respectivamente

$$\binom{n}{k} \text{ para muestras sin reposición, y}$$

$$\binom{n+k-1}{k} \text{ para muestras con reposición.}$$

(9) Demostración. Para las muestras ordenadas basta aplicar el principio ante enunciado con $n_j = (n-j+1)$ y $n_j = n, j=1, \dots, k$, respectivamente.

Para las muestras desordenadas, extraídas sin reposición, observamos que cada una de ellas da lugar a $k!$ muestras ordenadas, por tanto si su número es x , tendremos

$$V_{n,k} = k! \cdot x, \text{ de aquí } x = \frac{V_{n,k}}{k!} = \binom{n}{k}$$

para las extracciones con reposición puede remitirse al método de inducción para comprobar la fórmula dada, lo obstante vamos a presentar un método alternativo más elemental. Supongamos que las n bolas son n cartas numeradas del 1 al n y que los extraídos $k-1$ cartas, numeradas del $n+1$ a $n+k-1$ considerando cada una una reemplazo que dice: "repite la carta menor", "repite la 2ª carta menor", ..., "repite la $k-1$ ª carta menor". Extraer una muestra de tamaño k con reposición de entre las n cartas equivale a extraer una muestra de tamaño k sin reposición de entre las $n+k-1$ cartas, así pues su número vendrá dado por $\binom{n+k-1}{k}$.

Una aplicación de estas propiedades podemos verla en el siguiente ejemplo:

Ejemplo.- ¿Cuál es la probabilidad de que una mano de póker contenga exactamente un par?

Una mano de póker es un subconjunto de 5 cartas elegidas entre las 52 del mazo de cartas. El espacio muestral de los posibles manos de póker es finito y contiene exactamente $\binom{52}{5}$ puntos. Por otra parte, una mano de póker con un par contiene dos cartas iguales y las otras tres diferentes entre sí, y distintas de las que forman el par. Podemos obtener semejante mano mediante los siguientes pasos:

- 1) Elegir la carta que formará el par entre las 13 distintas de cada palo. Esto puede hacerse de $\binom{13}{1}$ formas.
- 2) Elegir la carta en 1), elegir las dos cartas de su número entre las cuatro (una de cada palo) que van a constituir la pareja. Lo tenemos de $\binom{4}{2}$ formas distintas.
- 3) Elegir ahora las tres cartas restantes, los números correspondientes, entre las 12 números que quedan después de eliminar el correspondiente a la pareja. Hay un total de $\binom{12}{3}$ formas de hacerlo.
- 4) Finalmente determinar para cada uno de los tres números elegidos, cuál es el palo elegido. Lo tenemos ahora de $4 \cdot 4 \cdot 4 = 4^3$ formas distintas.

Los casos favorables son pues $\binom{13}{1} \cdot \binom{4}{2} \cdot \binom{12}{3} \cdot 4^3$. De definir la probabilidad pedida vendrá dada por

$$\frac{\binom{13}{1} \cdot \binom{4}{2} \cdot \binom{12}{3} \cdot 4^3}{\binom{52}{5}} = \frac{1098240}{2598960} \approx 0.42$$

Otro problema interesante que puede plantearse es el de la ocupación de celdas mediante bolas. Generalizando este tipo de problemas, nos ocupamos en el número de problemas de ocupación. El teorema siguiente es útil en la solución de los mismos.

TEOREMA 2 - i) El número de maneras distintas en que n bolas, distintas, pueden distribuirse en k celdas distintas es k^n .

ii) Si deseamos que cada celda contenga un determinado número de bolas, sea i , la j -ésima celda contenga n_j bolas, $j=1, \dots, k$ ($n_j \geq 0, j=1, \dots, k, \sum n_j = n$), entonces la manera de llevar a cabo su distribución es

$$\frac{n!}{n_1! n_2! \dots n_k!} = \binom{n}{n_1, n_2, \dots, n_k}.$$

iii) Si las n bolas son indistinguibles pero las k celdas son distintas, entonces el número de distribuciones es

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

Además, si $n \geq k$ y ninguna celda debe estar vacía, entonces esta cantidad se convierte en

$$\binom{n-1}{k-1}.$$

Demostración - i) Cada una de las n bolas puede ocupar k posiciones distintas, por tanto k^n es el número de posibles distribuciones.

ii) El problema puede reducirse al de establecer k grupos con n bolas de manera que cada uno de ellos contenga un número determinado de bolas, exactamente n_j el j -ésimo grupo. Esto podemos hacerlo como sigue

$$\binom{n}{n_1} \binom{n-n_1}{n_2} \dots \binom{n-n_1-\dots-n_{k-1}}{n_k} = \frac{n!}{n_1! n_2! \dots n_k!} = \binom{n}{n_1, n_2, \dots, n_k}.$$

iii) El problema puede reducirse a una de las situaciones dadas y dadas en el teorema anterior. Supongamos una urna con k bolas numeradas de 1 a k , llevamos a cabo n extracciones con reposición y colocamos una bola en la celda que indica el número de la bola extraída, siguiendo el orden de aparición y consecutivamente. Batañi pues con determinar el número de vueltas, desordenadas de tamaño n , extraídas con reposición, que pueden obtenerse de una urna con k bolas numeradas de 1 a k . De acuerdo con el anterior teorema su número es

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

Si $n \geq k$ y queremos que todas las celdas contengan una bola al menos, depositamos la bola correspondiente de cada una y distribuimos como antes las $n-k$ restantes, tendremos

$$\binom{k+(n-k)-1}{n-k} = \binom{n-1}{n-k} = \binom{n-1}{k-1}.$$

EJEMPLO 3 - Tenemos n partículas, cada una de las cuales puede ocupar cada una de N ($N \geq n$) (11)

celdas, con la misma probabilidad, $1/N$. Enumerar la probabilidad de que:

- Hay una partícula en cada una de n celdas (fijas de antemano),
- Hay una partícula en cada una de n celdas, elegidas al azar.

Este problema es un problema clásico de ocupación que juega un papel importante en Mecánica Estadística. Como las condiciones del problema no aparecen determinadas, de manera única existen varias respuestas al mismo, tanto como distintas de maneras de definir el espacio muestral (conjunto de los posibles resultados), que dan lugar a las distintas estadísticas, unidas en Mecánica por el nombre de los autores que los desarrollaron. Estas son las tres respuestas que podemos dar a esta cuestión, con

1) Estadística de Boltzmann. Suponemos que las bolas y las celdas son distinguibles, haciendo uso del teorema 2 (apartado i) los casos posibles vendrán dados por N^n . Las respuestas a las dos probabilidades buscadas son

$$1.a) \quad p_1 = \frac{n!}{N^n}, \text{ hay } n! \text{ formas de disponer las partículas distinguibles en las } n \text{ celdas distintas.}$$

$$1.b) \quad p_2 = \frac{\binom{N}{n} n!}{N^n} = \frac{N!}{N^n (N-n)!}, \text{ } \binom{N}{n} \text{ son las formas de elegir las } n \text{ celdas entre las } N \text{ disponibles.}$$

2) Estadística de Bose-Einstein. Si bien las celdas continúan siendo distintas, las n partículas son ahora indistinguibles, por tanto, siempre recurriendo al teorema 2 el número de casos posibles es ahora $\binom{n+N-1}{n}$, las probabilidades buscadas

$$2.a) \quad p_1 = \frac{1}{\binom{n+N-1}{n}}, \text{ los casos favorables son 1 al no distinguirse las partículas}$$

$$2.b) \quad p_2 = \frac{\binom{N}{n}}{\binom{n+N-1}{n}} = \frac{N! (N-1)!}{(N-n)! (N+n-1)!}$$

3) Estadística de Fermi-Dirac. En esta estadística se supone que las celdas pueden contener a lo sumo 1 partícula, partícula que además no se distingue de las otras. Los casos posibles son pues $\binom{N}{n}$, las probabilidades

$$3.a) \quad p_1 = \frac{1}{\binom{N}{n}}$$


$$3.b) \quad p_2 = \frac{\binom{N}{n}}{\binom{N}{n}} = 1.$$

EMPLO 4. - En la taquilla de un matinal de bienes hay una cola de $2n$ niños, (13)
El precio de la entrada con 50 pesetas y de los $2n$ niños, n llevan monedas de 50 pts
y los n restantes llevan billetes de 100 pesetas. Si el cajero no tiene cambio cuando comienza
en el despacho de entradas, ¿Cuál es la probabilidad de que ningún niño deba
esperar para el cambio?

Resulta difícil en este caso la determinación del número de casos favorables
por métodos directos, para organizar los casos procedamos de la siguiente forma:

Representemos el orden de llegada a la taquilla en el eje de las x 's. Sobre
cada uno de los puntos levantaremos una ordenada que valdrá ± 1 si el niño va a pagar con
un billete de 100 pts y -1 si lleva una moneda de 50 pts (Círculos negros sobre la gráfica).

A continuación trazamos una
poligonal partiendo de $(0,0)$, cuyos
vértices son aquellos puntos que
tienen por abscisa el orden de
llegada y por ordenada la
acumulación de todas las ordena-
das anteriores no la instantánea
de los puntos en cuestión (véase la
figura adjunta). A esta poligonal
le llamaremos trayectoria. De



propiedades interesantes tiene la trayectoria así definida:

- Hay tantas trayectorias como ordenes distintos de llegada, a saber $\binom{2n}{n}$.
- Todas las trayectorias comienzan en $(0,0)$ y acaban en $(2n,0)$.

De todas las trayectorias, la que se comprenden con ordenes de llegada favorables a los circulados
requeridos en el enunciado son aquellas que no cruzan el eje de las x 's (hacia las y 's
positivas). Ello supone que en cada abscisa, es decir a la llegada de cada niño, los que llevaban
monedas de 50 pts han sido al menos ± 1 más que los que llevaban 100 pts para pagar su en-
trada, es decir, tenemos así garantizada la existencia de cambio para el niño correspondiente.
Vamos a determinar el número de estas trayectorias.

Utilizando la recta $y=1$, utilizada como eje de simetría, continuaremos nuestra trayectoria
a partir de los círculos. Estas nuevas trayectorias comienzan también en $(0,0)$, coinciden
con las antiguas mientras estas no alcanzan la recta $y=1$, cuando ello ocurre la recta hace
de eje de simetría de la trayectoria. Esto supone:

- La trayectoria que no alcanza $y=1$ conserva su forma inicial y no da lugar
a nuevas trayectorias ficticias. Observa que estas trayectorias son precisamente aquellas
que no cruzan el eje de las x 's, es decir, las favorables a la situación pedida.
- Las demás trayectorias, las exponables, dan lugar a nuevas trayectorias (línea di-
continua en la figura) que han finalizan en el punto $(2n,2)$. Ello quiere decir
que tienen 2 unidades más bajadas, es decir, 2 individuos más con billetes de 100 pts

que los que pagan con monedas de 50 pts. Su número será pues $\binom{2n}{n+1}$.

En definitiva el número de casos favorables vendrá dado por

$$\binom{2n}{n} - \binom{2n}{n+1}$$

y la probabilidad pedida será

$$p = \frac{\binom{2n}{n} - \binom{2n}{n+1}}{\binom{2n}{n}} = \frac{\frac{2n!}{n!n!} - \frac{2n!}{(n+1)!(n-1)!}}{\frac{2n!}{n!n!}} = 1 - \frac{n!n!}{(n+1)!(n-1)!} =$$

$$= 1 - \frac{n}{n+1} = \frac{n+1-n}{n+1} = \frac{1}{n+1}$$

FRECUENCIA Y PROBABILIDAD

La definición clásica de probabilidad surge en algunas situaciones, aquellos problemas
que se derivan de los ciencas experimentales, por ejemplo, dificultades insalvables para su aplica-
ción estrictamente. Es muy difícil actuar y determinar con exactitud los casos igualmente
probables o bien las condiciones de simetría que la equiprobabilidad comporta no se verifican
en las situaciones estudiadas, (destrucción de un átomo en un intervalo de tiempo dado, naci-
miento de un niño, etc.)

Buscando soluciones a estas situaciones, se ^{comproba} que la observación de la ocurrencia o no
ocurrencia de un suceso A, para un gran número de experimentos repetidos bajo un mismo
conjunto de condiciones simétricas que gran cantidad de fenómenos más de tal naturaleza
que el número de dichos sucesos (no ocurrencias) del suceso A obedece una ley estable.
Considerando, si m es el número de veces que ocurre A en n experiencias independientes (los
resultados de unas y otras no se influyen), se encuentra que la relación $\frac{m}{n}$, para n suficiente-
mente grande, es prácticamente constante, variando sus derivadas ~~proporcionalmente~~ cada vez menos
frecuente a medida que aumenta n .

Esta especie de stabilidad de la frecuencia (es decir, la relación m/n) fue puesta de
manifiesto primeramente para fenómenos demográficos y ello desde tiempos muy antiguos. Pasa-
re que en la China del año 2000 antes de Cristo ya había costumbre de inspeccionar
cerdos y a partir de las observaciones que ellos permitían reconsiderar que la frecuencia de
nacimiento de niños era una cantidad prácticamente constante alrededor de $\frac{1}{2}$. La sta-
bilidad de este nacimiento es un caso especialmente interesante ~~relacionado con la estabilidad~~,
podría decirse que incluso anecdótico. En efecto, Laplace en su libro Essai philoso-
phique sur les probabilités relata la siguiente anécdota:

Observamos que durante varios decadas, en varias ciudades europeas,
Londres, San Petersburgo, Berlín y en toda Francia se llegaban a la conclusión que el naci-
miento de niños presentaba una frecuencia extraordinariamente coincidente en el tiempo
y en el espacio, siendo dicho valor $22/43$. Estudió Laplace dichos nacimientos durante un

un periodo de 40 años (de 1745 a 1784) para la ciudad de París y encontró que su frecuencia era de $25/49$, cantidad ligeramente diferente de la anterior, pero lo suficiente para responder a Laplace. Profundizando más, en su estudio descubrió que en los centros utilitarios figuraban también los niños expósitos y que además, las personas de los suburbios de París tenían preferencia por abandonar niños de un solo sexo. En aquella época este fenómeno era bastante común y lo suficientemente importante como para alterar los resultados de la encuesta que se estaba llevando a cabo. Corregido el censo de otros niños reenumerados para París, una frecuencia de nacimientos de niños de $22/43$.

Desde la época de Laplace con muchos los experimentos llevados a cabo en este sentido. En la tabla se ven los resultados de distintos experimentos, llevados a cabo en la determinación de la frecuencia con que aparece cara en una serie de lanzamientos

Realizó la experiencia	Nº de lanzamientos	Nº de caras	Frecuencia
BUFFON	4040	2028	0.5080
KARL PEARSON	12000	6049	0.5016
KARL PEARSON	24000	12012	0.5005

La tecnología actual permite llevar cabo de manera sencilla y rápida estas comprobaciones de este hecho experimental (por ejemplo mediante la generación de números aleatorios con un ordenador).

La realización de este hecho induce a pensar en la existencia de cierta regularidad en determinados fenómenos, inherente a los mismos y por tanto independiente del experimentador. El hecho de que para los sucesos a los que se aplicable la definición de probabilidad, la estabilidad de sus frecuencias sitúe alrededor y muy cerca de dicha probabilidad, nos conduce, de manera lógica, a pensar que algo similar ocurre para sucesos de carácter general. No es pues extraño que decidamos denominar probabilidad del suceso A a la constante mínima alrededor de la cual oscilan las distintas frecuencias observadas para la ocurrencia de A.

Definición: Decimos que el suceso A tiene una probabilidad si posee la siguiente particularidad:

- Es posible, al menos teóricamente, llevar a cabo bajo las mismas condiciones y un número limitado de experimentos independientes, en cada uno de los cuales A puede o no ocurrir.
- Cuando el número de experimentos es suficientemente grande se observa que la frecuencia de aparición de A se acerca muy poco de una constante (generalmente denominada).

Esta constante denominada probabilidad estadística de A, para un gran número de experimentos, puede aproximarse mediante la frecuencia observada.

De esta definición, teniendo en cuenta las propiedades de las frecuencias, deducimos las siguientes propiedades para la probabilidad.

Propiedades de la probabilidad

- La probabilidad de un suceso que ocurre, es la unidad.
- La probabilidad del suceso imposible es cero.
- Si un suceso aleatorio G es la suma de un número finito de sucesos incompatibles $A_1, A_2, \dots, A_n$ que tienen probabilidad, entonces su probabilidad existe y es igual a la suma de las probabilidades de los componentes, es decir

$$P(G) = P(A_1) + P(A_2) + \dots + P(A_n).$$

Es interesante hacer algunas observaciones referente a esta definición de probabilidad.

Observaciones

- La definición de probabilidad que acabamos de dar es descriptiva, no resulta de una definición matemática. Definición formal tenemos como postulados la existencia de la probabilidad bajo ciertas condiciones y hemos indicado un método para aproximar su valor.
- Señalar además que la definición no pone de manifiesto las particularidades de aquellos fenómenos para los que la frecuencia es estable, si quisiéramos averiguarlos, deberíamos llevar a cabo investigaciones posteriores en este sentido. En cualquier caso la definición no pone de manifiesto el carácter objetivo de la probabilidad y su independencia del experimentador que lleva a cabo la experiencia.
- La importancia de la definición frecuencialista de la probabilidad (así como es la conocida en este nombre) estriba en el hecho de servir de punto de partida para la construcción de una teoría formal de la probabilidad que incidiera a su vez como una parte de la Matemática. Tanto es así, que en ocasiones la teoría de la probabilidad se define "como la parte de las Matemáticas que trata de los modelos matemáticos de los fenómenos aleatorios que poseen la propiedad de la estabilidad de las frecuencias".

CONSTRUCCIÓN AXIOMÁTICA DE LA TEORÍA DE LAS PROBABILIDADES

En las dos definiciones estudiadas hasta ahora ha quedado puesto de manifiesto la limitación de las mismas. Esta definición es doble, por un lado cuando aducen de una ~~deficiencia~~ falta de rigor matemático o de formalización matemática, no se refiere, por otra parte ninguna de las dos es exhaustiva por cuanto dejan fuera de su campo de aplicación muchos fenómenos. Esto, unido a los exigencias cada vez mayores de la ciencias experimentales, como primera, usuarias del concepto, planteó, a principios del siglo la necesidad de dar una solución general al problema. La solución pasaba, desde el punto de vista matemático, por la elaboración de una teoría formal mediante una axiomática adecuada, tal como se hace en otras partes de la Matemática. Las axiomas, cruciales no imponían, o debían suponer, un inicio en el desarrollo de la teoría, es decir, un estado inicial sin información previa, sino que por el contrario se iban derivando de los conocimientos que los resultados previos habían proporcionado (estas definiciones clásica y frecuencialista).

Por lo visto, S.N. Bernstein llevó a cabo un primer intento, en este sentido, hacia 1917. Construyó una axiomática sobre la base de comparar (nuevos aleatorios) en función de su mayor o menor probabilidad.

La solución definitiva al problema fue propuesta por A.N. Kolmogorov que definió una axiomática, hacia 1930, que relacionaba la teoría de la probabilidad con la teoría de conjuntos y la teoría de conjuntos. Partía Kolmogorov de una situación abstracta, para darle la mayor generalidad

posible, considerando inicialmente un espacio Ω de sucesos denumerables y una familia $\mathcal{S}$ (17) de partes de Ω cuyos elementos denominamos sucesos elementales. La familia de sucesos $\mathcal{S}$ verifica las siguientes condiciones:

- a) $\Omega \in \mathcal{S}$
- b) Si $A \in \mathcal{S}$ entonces $\bar{A} \in \mathcal{S}$
- c) Si $\{A_n\}_{n \geq 1} \subset \mathcal{S}$, entonces $\bigcup_{n \geq 1} A_n \in \mathcal{S}$.

Una familia con estas características se conoce con el nombre de σ -álgebra de sucesos o tribu de sucesos.

Los axiomas que introdujo Kolmogorov sobre Ω y los elementos de $\mathcal{S}$ fueron los siguientes:

A.I) A cada elemento de la σ -álgebra $\mathcal{S}$ le asociamos una cantidad no negativa a la que llamaremos su probabilidad. $P(A) \geq 0, \forall A \in \mathcal{S}$.

A.II) $P(\Omega) = 1$

A.III) Si $\{A_n\}_{n \geq 1} \subset \mathcal{S}$ y $A_i \cap A_j = \emptyset, i \neq j$, entonces

$$P\left(\bigcup_{n \geq 1} A_n\right) = \sum_{n \geq 1} P(A_n).$$

A partir de esta axiomática se desarrolla toda la Teoría Moderna de la Probabilidad, pero no lo haremos así nosotros, porque la probabilidad, definida mediante estos axiomas, se introduce en el contexto más general de la Teoría de la Medida, y así como vamos a actuar en el próximo capítulo.

Antes de terminar con este tema señalar dos propiedades que el sistema de axiomas de Kolmogorov posee:

1) El sistema de axiomas es consistente, puesto que existen objetos reales que satisfacen todos los axiomas. Si tomamos $\Omega = \{a_1, a_2, \dots, a_n\}$, los a_i cualesquiera y si $\mathcal{S} = \mathcal{P}(\Omega)$, haciendo $P(a_i) = p_i$, con $p_i \geq 0$ y tales que $p_1 + p_2 + \dots + p_n = 1$ y si para $A \in \mathcal{S}$, tal que $A = \{a_{i_1}, a_{i_2}, \dots, a_{i_k}\}$, definimos $P(A) = p_{i_1} + \dots + p_{i_k}$, entonces los axiomas de Kolmogorov se satisfacen.

2) El sistema es incompleto puesto que para un mismo Ω podemos elegir las probabilidades en $\mathcal{S}$ de formas diferentes. Por ejemplo para el caso del lanzamiento de un dado, $\Omega = \{E_1, \dots, E_6\}$ podemos tomar $P(E_i) = 1/6, i=1, \dots, 6$, o bien hacerlo de la forma

$$P(E_1) = P(E_2) = P(E_3) = 1/4 \text{ y } P(E_4) = P(E_5) = P(E_6) = 1/12,$$

por supuesto de ambas formas el sistema de axiomas se satisfacen.

La incompletitud del sistema de axiomas no significa en absoluto un fracaso para explicar o desarrollar la teoría estudiada, en este caso la teoría de la probabilidad, al contrario, y debido a la esencia de la materia en estudio. En efecto, en el caso del dado, si se trata de un dado perfecto el modelo probabilístico adecuado para describirlo será el primero, ya que en él que todos los casos tienen probabilidad $1/6$, en caso de tratarse de un dado irregular quizá el segundo modelo se ajuste más a la realidad.

Capítulo 2

Probabilidad y medida

PROBABILIDAD Y MEDIDA

ALGEBRAS Y σ -ALGEBRAS

Definición - Sea Ω un conjunto y sea $\mathcal{A}$ una subfamilia de $\mathcal{P}(\Omega)$, decimos que $\mathcal{A}$ tiene estructura de álgebra si verifica:

- 1) $\Omega \in \mathcal{A}$
- 2) Si $A \in \mathcal{A}$ entonces $A^c \in \mathcal{A}$
- 3) Si $A, B \in \mathcal{A}$ entonces $A \cup B \in \mathcal{A}$.

De esta definición se deducen de inmediato las siguientes propiedades

Propiedades

- 1) $\emptyset \in \mathcal{A}$
- 2) Si $\{A_i\}_{i=1}^n \subset \mathcal{A}$, entonces $\bigcup_{i=1}^n A_i \in \mathcal{A}$ y $\bigcap_{i=1}^n A_i \in \mathcal{A}$

Ejemplos de álgebras

- 1) $\mathcal{A} = \{\emptyset, \Omega\}$ es un álgebra (el álgebra trivial)
- 2) $\mathcal{A} = \{\text{subconjuntos de } \Omega\} = \mathcal{P}(\Omega)$ es también un álgebra
- 3) Para $A \subset \Omega$, $\mathcal{A} = \{\emptyset, A, A^c, \Omega\}$ es un álgebra.
- 4) Sea Ω un conjunto infinito, entonces $\mathcal{A} = \{A \subset \Omega / A \text{ o } A^c \text{ es finito}\}$ es un álgebra.

Las álgebras aseguran la estabilidad para las uniones e intersecciones de sus elementos en número finito. Nada puede asegurarse acerca de estas operaciones cuando se tienen a cabo en número infinito numerable. La solución a este problema llega por vía de la generalización mediante la siguiente estructura.

Definición - Sea Ω un conjunto y sea $\mathcal{B}$ una subfamilia de $\mathcal{P}(\Omega)$, decimos que $\mathcal{B}$ es un σ -álgebra si verifica:

- 1) $\mathcal{B}$ es un álgebra
- 2) Si $\{A_n\}_{n \in \mathbb{N}} \subset \mathcal{B}$, entonces $\bigcup_{n \in \mathbb{N}} A_n \in \mathcal{B}$.

Al igual que para los álgebras también son $\bigcap_{n \in \mathbb{N}} A_n \in \mathcal{B}$, propiedad que se deriva directamente de la definición. Como ejemplos de σ -álgebras podemos citar:

Ejemplos de σ -álgebras

- 1) $\mathcal{B} = \{\emptyset, \Omega\}$ es la σ -álgebra trivial
- 2) $\mathcal{B} = \mathcal{P}(\Omega)$ es una σ -álgebra.

Una estructura interesante y útil se engendra a partir de una familia de subconjuntos del espacio Ω inicial llamado.

Observación - Las σ -álgebras, redondean también, en ocasiones, tribus.

① Estructuras engendradas

Sea Ω un conjunto y sea $\mathcal{Z}$ un subconjunto de $\mathcal{P}(\Omega)$ que posee o no alguna estructura concreta. Sean $\{A_i\}_{i \in I}$, $\{B_j\}_{j \in J}$ las familias de álgebras y σ -álgebras que contienen a $\mathcal{Z}$. Hay que decir que dichas familias son no vacías por cuanto ambas contienen a $\mathcal{P}(\Omega)$. A partir de ellas, obtenemos

$$\mathcal{A}(\mathcal{Z}) = \bigcap_{i \in I} A_i, \quad \mathcal{B}(\mathcal{Z}) = \bigcap_{j \in J} B_j.$$

Es fácil comprobar que estas familias de conjuntos así definidas verifican:

- | | |
|---|---|
| 1.a) $\mathcal{A}(\mathcal{Z})$ es un álgebra | 1.b) $\mathcal{B}(\mathcal{Z})$ es una σ -álgebra |
| 2.a) $\mathcal{Z} \subset \mathcal{A}(\mathcal{Z})$ | 2.b) $\mathcal{Z} \subset \mathcal{B}(\mathcal{Z})$ |
| 3.a) $\mathcal{A}(\mathcal{Z})$ es la mínima álgebra que contiene a $\mathcal{Z}$. | 3.b) $\mathcal{B}(\mathcal{Z})$ es la mínima σ -álgebra que contiene a $\mathcal{Z}$. |

$\mathcal{A}(\mathcal{Z})$ y $\mathcal{B}(\mathcal{Z})$ se llaman, respectivamente, álgebra y σ -álgebra engendrada por la familia $\mathcal{Z}$. La utilidad de esta construcción alaba en el hecho de permitir definir estructuras a partir de familias de conjuntos específicas. Sin embargo, dada el caso más interesante es cuando Ω no es un conjunto cualquiera sino que se trata de un espacio topológico. Aparece entonces la tribu de Borel, de la que los valores ocupará continuación.

La tribu de Borel β - Si Ω es un espacio topológico posee un sistema de abiertos y cerrados. Definimos, mediante el proceso antes admitido, la σ -álgebra engendrada por el sistema de abiertos, $\mathcal{B}(\mathcal{O})$, dicha σ -álgebra se conoce como la σ -álgebra de Borel del espacio topológico Ω y se la designa mediante β . Esta σ -álgebra tiene entre otras, las siguientes propiedades, digase, de mencionar:

- a) $\mathcal{B}(\mathcal{F}) \equiv \beta$
- b) ~~Observación~~ Si S es una familia de abiertos que, cuando numerable, engendra el sistema de abiertos, es decir, si se trata de una base numerable del espacio topológico Ω , entonces $\mathcal{B}(S) = \beta$.

El caso de tribu de Borel especialmente interesante para nosotros es aquel en que $\Omega = \mathbb{R}$. Haciendo uso de la propiedad b) podemos afirmar que, como $\mathbb{R}$ posee una base numerable, ~~por~~ la tribu de Borel de la recta real viene engendrada por una familia de intervalos cualquiera. Así, por ejemplo, si tomamos $S = \{]x, y[, x, y \in \mathbb{R}, x < y\}$, entonces $\mathcal{B}(S) = \beta$. Si hubiéramos tomado los extremos racionales para definir los intervalos el resultado hubiera sido el mismo. Esta utilidad en la construcción de β será útil posteriormente.

La tribu de Borel en $\mathbb{R}^2$, o en general en $\mathbb{R}^k$, β^2 o β^k respectivamente, se define análogamente a partir de familias de rectángulos (productos de intervalos) cuyos proyecciones son intervalos con extremos

cualquiera. Por ejemplo, para $\mathbb{R}^2$, $\mathbb{R}^2$ puede ser engendrada por la familia (3)

$$S = \{ [x_1, y_1] \times [x_2, y_2], \text{ con } x_1, y_1, x_2, y_2 \in \mathbb{R}; x_1 < y_1, x_2 < y_2 \}.$$

Definición.- Al par formado por un conjunto Ω y una σ -álgebra de sus partes se le denomina espacio medible y se denota mediante $(\Omega, \mathcal{A})$.

MEDIDA

Sea $(\Omega, \mathcal{A})$ un espacio medible, definimos sobre $\mathcal{A}$ una función de conjuntos, μ , que verifica

- 1) $\mu(\emptyset) = 0$
- 2) $\mu(A) \geq 0, \forall A \in \mathcal{A}$
- 3) Si $\{A_n\}_{n \geq 1} \subset \mathcal{A}$ y $A_n \cap A_m = \emptyset, n \neq m$, entonces

$$\mu\left(\bigcup_{n \geq 1} A_n\right) = \sum_{n \geq 1} \mu(A_n).$$

Brinamos entonces que μ es una medida sobre $\mathcal{A}$. A la terna $(\Omega, \mathcal{A}, \mu)$ la denominamos espacio de medida. Una consecuencia inmediata de esta definición es la monotonia de la medida, es decir

$$\text{si } A \subset B, \text{ entonces } \mu(A) \leq \mu(B).$$

aplicando 3) tenemos

$$\mu(B) = \mu(A) + \mu(B-A)$$

y como por 2) $\mu(B-A) \geq 0$, de aquí $\mu(B) \geq \mu(A)$. Es decir, la medida es monotona creciente.

Son muchas las propiedades de interés que posee una medida, no nos ocuparemos de ellas, destacando ahora más que los estudiantes a medida que van necesitando en el desarrollo del desarrollo del tema. Si tiene interés ver más acerca algunos de los distintos tipos de medidas, con las que podremos encontrarlos.

Medida σ -finita.- Sea $(\Omega, \mathcal{A}, \mu)$ un espacio de medida, decimos que μ es σ -finita si $\forall A \in \mathcal{A}$,

$$\exists \{A_n\}_{n \geq 1} \subset \mathcal{A} / A \subset \bigcup_{n \geq 1} A_n \text{ y } \mu(A_n) < +\infty, \forall n.$$

Medida finita.- Sea $(\Omega, \mathcal{A}, \mu)$ un espacio de medida, decimos que μ es finita si $\mu(\Omega) < +\infty$.

Esto implica, dada la monotonia de μ , que $\mu(A) < +\infty, \forall A \in \mathcal{A}$.

Ejemplo.- Una medida de uso muy común en Análisis Matemático es la que se conoce con el nombre de Medida de Lebesgue, porque fue Lebesgue quien la introdujo a principios de siglo para desarrollar su famosa teoría de la Integración, teoría que por otra parte va directamente ligada a la teoría de las medidas. En su versión univariante, la medida de Lebesgue se define sobre el espacio medible $(\mathbb{R}, \mathcal{B})$ como aquella que ~~con~~ cada intervalo le hace corresponder su longitud, cuando los extremos son finitos, o vale infinito sobre los intervalos con algún extremo infinito. A se le llama aquí para entrar en detalle

de esta definición y propiedades de esta medida.

En su versión k-dimensional, la medida se define sobre el espacio medible $(\mathbb{R}^k, \mathcal{B}^k)$, $k \geq 2$ haciendo que sobre los hiperrectángulos de k-dimensiones, $\prod_{i=1}^k [x_i, y_i]$ valga el hiperípedo más correspondiente (area para $k=2$, volumen para $k=3$, etc.) si los extremos de los intervalos son finitos, o bien valga infinito en cualquier otro caso.

Dadas las características topológicas de $\mathbb{R}$ y $\mathbb{R}^k$, $k \geq 2$ podemos afirmar que las distintas medidas de Lebesgue son σ -finitas.

Ejemplo.- Otro ejemplo de medida definida sobre un espacio medible $(\Omega, \mathcal{A})$, es aquella definida como sigue:

$$\forall A \in \mathcal{A}, \mu(A) = \{\text{número de elementos de } A\} = \text{card}(A).$$

Se puede fácilmente ver que es una medida a la que se conoce como medida de cardinalidad o medida de conteo (counting measure). Si Ω es finito, obviamente μ es finita. De otra manera, solo que sobre un la medida de Lebesgue, esta medida no es σ -finita, si Ω es infinito no numerable, por que si fuera infinito numerable,

$$\Omega = \{w_1, \dots, w_n, \dots\}, \text{ entonces } \Omega = \bigcup_{n \geq 1} \{w_n\} \text{ y como } \mu(\{w_n\}) = 1$$

entonces μ es σ -finita por $\forall A \in \mathcal{A}, A \subset \Omega$.

Vamos ahora ya a ocuparnos del objeto de estos estudios, es decir, las medidas de probabilidad.

MEDIDA DE PROBABILIDAD

Una medida de probabilidad no es más que una medida para la que $\mu(\Omega) = 1$. Es costumbre de este caso denotar la medida mediante la letra P y hablar de $(\Omega, \mathcal{A}, P)$ como de un espacio de probabilidad y denominar a Ω espacio muestral y a $\mathcal{A}$ σ -álgebra de sucesos.

Ejemplo 1.- Sea $\Omega = \{w_1, \dots, w_n\}$ y sea $\mathcal{A} = \mathcal{P}(\Omega)$, definimos P de la siguiente manera

$$P(A) = \sum_{j=1}^n P(\{w_j\}), \text{ con } A = \{w_{i_1}, \dots, w_{i_p}\}$$

$$\text{además, } P(\{w_i\}) = \frac{1}{n} = P(\{w_n\}) = \frac{1}{n}.$$

La función así definida es una medida de probabilidad, más convenientemente se conoce como probabilidad uniforme y coincide con la definición dada de Lebesgue. Puede verse así de manifiesto que esta nueva definición de la probabilidad es más general, contiene aquella como caso particular.

Ejemplo 2.- Sea $\Omega = [0, 1]$ y $\mathcal{A} = \mathcal{B}_{[0,1]}$ tribu de Borel sobre el espacio $[0, 1]$. Definimos P mediante

$$P(A) = \text{longitud}(A), \text{ donde } A \text{ es un subintervalo de } \Omega.$$

P define una probabilidad que se conoce como la probabilidad uniforme sobre el intervalo $[0, 1]$.

Ejemplo 3.- Sea $\Omega = \{\omega_1, \omega_2\}$ y sea $\mathcal{B} = \mathcal{P}(\Omega)$, definimos P mediante

$$P(\{\omega_1\}) = p \quad \text{y} \quad P(\{\omega_2\}) = 1-p, \quad (0 \leq p \leq 1)$$

$(\Omega, \mathcal{B}, P)$ constituye un espacio de probabilidad.

Propiedades de la medida de probabilidad

1) P es finitamente aditiva.

En efecto, notemos que si $\{A_n\}_{n \geq 1} \subset \mathcal{B}$ con $A_n \cap A_m = \emptyset$, $n \neq m$ entonces

$$P\left(\bigcup_{n \geq 1} A_n\right) = \sum_{n \geq 1} P(A_n) \quad (\text{finitud aditiva de la medida de probabilidad}).$$

Si al menos de sucesos es finito, a saber, $A_1, \dots, A_n$, entonces podemos considerar $A_k = \emptyset$, $k \geq n+1$, y de aquí, aplicar la anterior condición y obtener

$$P\left(\bigcup_{i=1}^n A_i\right) = P\left(\bigcup_{n \geq 1} A_n\right) = \sum_{n \geq 1} P(A_n) = \sum_{i=1}^n P(A_i), \text{ por ser } P(\emptyset) = 0.$$

2) $\forall A, B \in \mathcal{B}$, $P(A \cup B) = P(A) + P(B) - P(A \cap B)$.

$$A \cup B = A \cup (B - A) \text{ y por la aditividad finita } P(A \cup B) = P(A \cup (B - A)) = P(A) + P(B - A)$$

$$\text{pero } B = (B - A) \cup (A \cap B) \text{ y } P(B) = P(B - A) + P(A \cap B), \text{ deducir } P(B - A) = P(B) - P(A \cap B)$$

substituyendo

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

3) P es subaditiva, a saber, para $\{A_n\}_{n \geq 1} \subset \mathcal{B}$, cualquiera $P\left(\bigcup_{n \geq 1} A_n\right) \leq \sum_{n \geq 1} P(A_n)$.

A partir de la sucesión $\{A_n\}_{n \geq 1}$ podemos definir una nueva sucesión como sigue

$$B_n = A_n - \bigcup_{i=1}^{n-1} A_i$$

sto B_n son mutuamente excluyentes, $A_n \supset B_n$ y además $B_n \cap B_m = \emptyset$, $n \neq m$ con $\bigcup_{n \geq 1} B_n = \bigcup_{n \geq 1} A_n$, entonces

$$P\left(\bigcup_{n \geq 1} A_n\right) = P\left(\bigcup_{n \geq 1} B_n\right) = \sum_{n \geq 1} P(B_n) \leq \left[\text{por monotonicidad}\right] \leq \sum_{n \geq 1} P(A_n).$$

La desigualdad es también válida para un número finito de sucesos.

TEOREMA.- Sea $\{A_i\}_{i=1}^n \subset \mathcal{B}$, entonces

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i_1 < i_2 \leq n} P(A_{i_1} \cap A_{i_2}) + \sum_{1 \leq i_1 < i_2 < i_3 \leq n} P(A_{i_1} \cap A_{i_2} \cap A_{i_3}) - \dots + (-1)^{n+1} P(A_1 \cap A_2 \cap \dots \cap A_n).$$

demostración.- Se comprueba fácilmente por inducción sobre n .

5) Sucesiones monótonas de conjuntos (sucesos)

6)

Sea $\{A_n\}_{n \geq 1}$ una sucesión de conjuntos, se definen los límites superior e inferior de la siguiente forma

$$\limsup_n A_n = \bigcap_{n \geq 1} \bigcup_{i \geq n} A_i, \quad \text{límite superior}$$

$$\liminf_n A_n = \bigcup_{n \geq 1} \bigcap_{i \geq n} A_i, \quad \text{límite inferior}$$

Cuando ambos límites coinciden, decimos que la sucesión tiene límite.

Hay una situación en la que sta siempre garantizada la existencia del límite. Este es el caso de las sucesiones monótonas, que pueden ser de dos tipos:

a) Una sucesión de conjuntos se dice que es monótona decreciente o contractiva si $A_n \supset A_{n+1}$, $\forall n$.

b) Una sucesión de conjuntos se dice que es monótona creciente o expansiva si $A_n \subset A_{n+1}$, $\forall n$.

Es fácil comprobar para este tipo de sucesiones que,

$$\text{Si } \{A_n\}_{n \geq 1} \text{ es contractiva } \limsup_n A_n = \liminf_n A_n = \bigcap_{n \geq 1} A_n = \lim_n A_n$$

$$\text{Si } \{A_n\}_{n \geq 1} \text{ es expansiva } \limsup_n A_n = \liminf_n A_n = \bigcup_{n \geq 1} A_n = \lim_n A_n$$

Cuando se trata de sucesiones de sucesos existe una importante propiedad de las probabilidades basada en sucesiones monótonas. Es la siguiente

TEOREMA (Continuidad (upper) del peso al límite).- Sea $\{A_n\}_{n \geq 1}$ una sucesión monótona de sucesos, entonces

$$P\left(\lim_n A_n\right) = \lim_n P(A_n).$$

Demostración.- a) Supongamos que $\{A_n\}_{n \geq 1}$ es expansiva, entonces $\lim_n A_n = \bigcup_{n \geq 1} A_n$. Definimos una nueva sucesión

$$A'_n = A_n - A_{n-1}, \quad n \geq 2, \quad A'_1 = A_1,$$

Los elementos satisfacen $A'_n \cap A'_m = \emptyset$ y $\bigcup_{n \geq 1} A'_n = \bigcup_{n \geq 1} A_n$. A partir de aquí

$$\begin{aligned} P\left(\lim_n A_n\right) &= P\left(\bigcup_{n \geq 1} A_n\right) = P\left(\bigcup_{n \geq 1} A'_n\right) = \sum_{n \geq 1} P(A'_n) = \lim_{n \rightarrow \infty} \sum_{i=1}^n P(A'_i) = \\ &= \lim_{n \rightarrow \infty} P\left(\bigcup_{i=1}^n A'_i\right) = \lim_{n \rightarrow \infty} P(A_n). \end{aligned}$$

b) Si $\{A_n\}_{n \geq 1}$ es contractiva la sucesión $\{A_n^c\}_{n \geq 1}$ será expansiva y $\lim_n A_n^c = \bigcup_{n \geq 1} A_n^c$.

Es fácil comprobar por otra parte que para un suceso A su complementario A^c , se verifica

$$P(A) + P(A^c) = 1.$$

Por el apartado anterior sabemos que

$$P(\lim_n A_n^c) = \lim_n P(A_n^c) = P(\bigcup_{n \geq 1} A_n^c)$$

utilizando la propiedad dual

$$\lim_n P(A_n^c) = \lim_n [1 - P(A_n)] = P([\bigcap_{n \geq 1} A_n]^c) = 1 - P(\bigcap_{n \geq 1} A_n)$$

y de aquí

$$\lim_n P(A_n) = P(\bigcap_{n \geq 1} A_n) = P(\lim_n A_n).$$

Señala de aquí la Variedad continuidad en el ϕ de la Probabilidad y que damos en forma de

Corolario:- Si $\{A_n\}_{n \geq 1}$ es una sucesión monótona decreciente, tal que $\lim_n A_n = \phi$, entonces $\lim_n P(A_n) = 0$.

La importancia de este corolario radica en el hecho de que es equivalente a la aditividad completa o σ -aditividad postulada para la medida (en este caso para la probabilidad). La implicación en el sentido σ -aditividad $\rightarrow$ continuidad en ϕ está ya comprobada en el teorema anterior por cuanto en él hemos hecho de la citada σ -aditividad. Concluimos la sección con esto.

Teorema:- Sustituyendo en la definición de medida de probabilidad la σ -aditividad por la continuidad en ϕ , tenemos que,

$$\text{Si } \{A_n\}_{n \geq 1} \subset \mathcal{A} / A_n \cap A_m = \phi, \text{ entonces } P(\bigcup_{n \geq 1} A_n) = \sum_{n \geq 1} P(A_n).$$

Demostración:- Definamos $A = \bigcup_{n \geq 1} A_n$, $B_n = \bigcup_{i=1}^n A_i$
 $B_n' = A - B_n$.

La sucesión $\{B_n'\}_{n \geq 1}$ es decreciente y $\lim_n B_n' = \phi$, aplicando la continuidad en ϕ de la Probabilidad, tenemos

$$P(\lim_n B_n') = \lim_n P(B_n') = 0$$

$$\text{pero } \lim_n P(B_n') = \lim_n P(A - B_n).$$

Se comprueba fácilmente, que para dos sucesos cualesquiera E, F tales que $F \subset E$, verifica que $P(E-F) = P(E) - P(F)$, aplicando esto

$$\lim_n P(B_n') = \lim_n [P(A) - P(B_n)] = P(A) - \lim_n \sum_{i=1}^n P(A_i) = P(A) - \sum_{i=1}^{\infty} P(A_i) = 0$$

$$\text{de aquí } P(A) = \sum_{n \geq 1} P(A_n).$$

la serie converge

Observación:- Debemos señalar que en ocasiones nos encontramos con sucesos tales que su probabilidad sea 0, esto no implica en modo alguno que se trate del ϕ , de la misma manera que hay sucesos tales que su probabilidad es 1 y no por ello coinciden con el espacio muestral.

⑦ Vamos algunos ejemplos de medidas de Probabilidad.

Ejemplos

① Sea Ω el conjunto de los naturales con el cero. Sea $\mathcal{A}$ la σ -álgebra de los subconjuntos de Ω . Sobre el espacio medible $(\Omega, \mathcal{A})$ definimos una función de conjunto P , mediante

$$\forall A \in \mathcal{A}, P(A) = \sum_{x \in A} \frac{e^{-\lambda} \cdot \lambda^x}{x!}, \lambda > 0.$$

La función P verifica

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

$$b) P(A) \geq 0, \forall A \in \mathcal{A}$$

$$c) \text{ Para } \{A_n\}_{n \geq 1} \subset \mathcal{A}, \text{ tal que } A_n \cap A_m = \phi, n \neq m, \text{ tenemos}$$

$$A = \bigcup_{n \geq 1} A_n \quad y \quad P(A) = \sum_{x \in A} \frac{e^{-\lambda} \cdot \lambda^x}{x!} = \sum_{n \geq 1} \sum_{x \in A_n} \frac{e^{-\lambda} \cdot \lambda^x}{x!} = \sum_{n \geq 1} P(A_n).$$

Así pues de una medida. Además

$$P(\Omega) = \sum_{x \in \Omega} \frac{e^{-\lambda} \cdot \lambda^x}{x!} = \sum_{x \geq 0} \frac{e^{-\lambda} \cdot \lambda^x}{x!} = e^{-\lambda} \cdot \sum_{x \geq 0} \frac{\lambda^x}{x!} = e^{-\lambda} \cdot e^{\lambda} = 1.$$

y es por tanto una medida de Probabilidad.

② Sobre el mismo espacio medible del ejemplo anterior, definimos P , mediante

$$\forall A \in \mathcal{A}, P(A) = 1, \text{ si } A \text{ tiene un número finito de puntos}$$

$$P(A) = 0, \text{ en caso contrario.}$$

La P así definida no es una medida de probabilidad por que ni siquiera es una medida. Efectivamente no verifica la σ -aditividad, por tomando $A_n = \{n\}$, $n \geq 1$, tenemos

$$\bigcup_{n \geq 1} A_n = \mathbb{N}, \quad P(\mathbb{N}) = 0 \text{ por contener un } \infty \text{ de puntos}$$

$$\text{mientras que } P(A_n) = 1, \text{ for } n \text{ por tanto } \sum_{n \geq 1} P(A_n) = +\infty.$$

③ Existe una medida de probabilidad especialmente importante que da lugar a lo que generalmente se conoce como Probabilidad geométrica, por cuanto la atención se la probabilidad de cualquier suceso A se define mediante en las características geométricas del mismo. Vamos a ello.

Tomemos $\mathbb{R}^n$ como espacio muestral y sea β^n la tribu de Borel de $\mathbb{R}^n$. Sobre el espacio medible $(\mathbb{R}^n, \beta^n)$ consideremos la medida de Lebesgue en $\mathbb{R}^n$, μ (Recordemos que esta medida a cada elemento de β^n le hace corresponder su "volumen").

Sea ahora $\Omega \in \beta^n$ tal que $\mu(\Omega) < +\infty$. Restringimos nuestra atención a este conjunto y lo dotamos de la σ -álgebra de sucesos $\beta_\Omega^n = \{A / A \subset \Omega \text{ y } A \in \beta^n\}$, definimos P de la siguiente manera

$$P(A) = \frac{\mu(A)}{\mu(\Omega)}, \quad \forall A \in \beta_\Omega^n.$$

Es muy fácil comprobar que P es una medida, teniendo en cuenta que μ lo es. Es además una medida de probabilidad porque estáticamente está normalizada (vale 1 sobre Ω), ya que

$$P(\Omega) = \frac{\mu(\Omega)}{\mu(\Omega)} = 1.$$

Para $n=2$ entendemos de inmediato el significado físico de este tipo de medida de probabilidad. En $\mathbb{R}^2$, la medida de Lebesgue es el área del conjunto de fase considerado y la probabilidad definida supone que para un suceso A , la probabilidad es proporcional al área que dicho suceso representa. Veamos un ejemplo que nos aclare estos conceptos.

Ejemplo de probabilidad geométrica. - Dos personas A y B acuerdan una cita en un lugar determinado entre las doce y la una del mediodía. El primero en llegar espera 20 minutos al otro y después se va. ¿Cuál es la probabilidad de que A y B se encuentren si la llegada de ambos es aleatoria dentro de la hora fijada?

Esta definición de probabilidad geométrica que hemos dado ha implicado una indicación de uniformidad en cuanto a la distribución de la probabilidad en todo el superespacio que Ω representa. Es decir que la elección de puntos en Ω es completamente aleatoria. El problema que nos ocupa explicita esta indicación y podemos intentar contestarlo de acuerdo con el tipo de probabilidad definida. Designemos por x e y los tiempos de llegada de A y B respectivamente. Se acuerda en la hipotesis que el tiempo dado plantea A y B se encuentran si

$$|x - y| \leq 20$$

(x y y se expresan en minutos)

Si representamos gráficamente la desigualdad veremos que el suceso E , se encuentra, viene representado geométricamente por la parte sombreada de la figura. Mientras que todo el primer cuadrante de la figura representa el suceso Ω de la definición de probabilidad geométrica. La probabilidad buscada viene pues dada por

$$P(E) = \frac{\text{Superficie}(E)}{\text{Superficie}(\Omega)} = \frac{60^2 - 2 \times 40^2/2}{60^2} = \frac{3600 - 1600}{3600} = \frac{2000}{3600} = \frac{5}{9}.$$

El concepto de probabilidad geométrica fue introducido por BUFFON, en el siglo 18, mediante un problema ya famoso en la historia de la Teoría de la Probabilidad; el problema de la aguja de BUFFON. Consiste en determinar la probabilidad de que al lanzar aleatoriamente una aguja de longitud $2l$ sobre un plano en el que se han pintado paralelas que distan entre sí $2a$ ($l < a$), la aguja intersecte alguna de ellas. Los experimentos de la solución de este problema en su momento.

Como en el siglo 18 los conceptos de medida y medida de Lebesgue no eran conocidos la solución se planteaba directamente en términos de superficies planas.

Señalar finalmente dos aspectos interesantes:

a) El concepto de probabilidad geométrica supone una generalización de la definición clásica

de probabilidad. Allí en realidad utilizábamos para medir los conjuntos una medida adecuada para aquellas circunstancias, a saber, el cardinal de los conjuntos. Aquí, puesto que se trata de elementos de otra naturaleza recurrimos a la medida de Lebesgue como medida para hacerlo.

b) Cuando introduzcamos el concepto de variable aleatoria y de independencia entre variables, veremos como este tipo de problemas puede verse dentro de un contexto más general, definiendo la probabilidad de que las variables tomen valores en determinado conjunto sucesos de la σ -álgebra de probabilidad.

PROBABILIDAD CONDICIONAL

El concepto de probabilidad manejado hasta ahora ha conocido bastantes variaciones, como probabilidad incondicional o absoluta por contraponerle al que vamos a introducir a continuación. Aquí, no obstante, de principio formalmente vamos a intentar dar alguna motivación intuitiva de su validez.

Supongamos que tenemos un dado cúbico en el que hemos pintado de rojo las caras que tienen 4, 4 y 6 puntos, de azul las restantes. Si lanzamos el dado una vez, vemos que la probabilidad de que aparezca un 6 es $\frac{1}{6}$ (definición clásica) ahora bien, si después del lanzamiento nos es permitido mirar el dado de tal forma que podamos distinguir el color de cada cara, pero no su número y si observamos que se da cara a rojo, entonces podemos afirmar que la probabilidad de obtener 6 es ahora $\frac{1}{3}$. Esta última probabilidad viene condicionada por el hecho de conocer de antemano el color que ha aparecido en el lanzamiento y además se observa que su valor viene dado por

$$P(\text{sale 6} \text{ condicionada a que haya salido rojo}) = \frac{P(\text{sale 6 y rojo})}{P(\text{rojo})} = \frac{1/6}{1/2} = \frac{1}{3},$$

lo que utilizando una notación más simplificada y si $A = \{\text{sale 6}\}$, $B = \{\text{sale rojo}\}$, queda

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

donde $P(A/B)$ designa la probabilidad del suceso A condicionada a que ha ocurrido B .

Daremos ahora una definición formal del concepto.

Definición. - Sea $(\Omega, \mathcal{B}, P)$ un espacio de probabilidad, sea A un suceso tal que $P(A) > 0$. Definimos una función de conjunto sobre los elementos de $\mathcal{B}$ mediante

$$P(B/A) = \frac{P(A \cap B)}{P(A)}, \quad \forall B \in \mathcal{B}.$$

a la que denominamos probabilidad del suceso B condicionada a la ocurrencia del suceso A , o simplemente probabilidad condicional de B , dado A .

Observación. - No es una casualidad designar a la función de conjuntos así definida con el nombre de probabilidad condicional. Este nombre se justifica plenamente cuando comprobamos (cosa que se hace muy fácilmente) que la función así definida es una medida de probabilidad y posee por tanto todas las propiedades inherentes al concepto.

TEOREMA (Regla de multiplicación).- Sea $(\Omega, \mathcal{A}, P)$ un espacio de probabilidad y sean $\{A_i\}_{i=1}^n \subset \mathcal{A}$, tales que $P(\bigcap_{i=1}^n A_i) > 0$. Entonces

$$P\left(\bigcap_{i=1}^n A_i\right) = P(A_1) \cdot P(A_2/A_1) \cdot P(A_3/A_1 A_2) \cdot \dots \cdot P(A_n / \bigcap_{i=1}^{n-1} A_i).$$

la demostración es sencilla que deja al estudiante (se omite).

El interés de la fórmula que nos proporciona reside en el hecho de que en ocasiones es mucho más sencillo obtener las probabilidades del 2º miembro de la igualdad que la probabilidad del primer miembro. Veamos un ejemplo.

Ejemplo.- Una urna contiene 10 bolas idénticas, de las cuales 5 son rojas, 3 rojas y 2 blancas. Se extraen cuatro bolas sin reposición. Probabilidad de que la primera sea roja, la segunda, blanca la tercera y la cuarta roja.

Sean $N_1 \rightarrow$ la 1ª bola es roja $B_3 \rightarrow$ la 3ª bola es blanca
 $R_2 \rightarrow$ la 2ª bola es roja $N_4 \rightarrow$ la 4ª bola es roja.

No pueden obtener

$$P(N_1 \cap R_2 \cap B_3 \cap N_4)$$

haciendo uso del teorema tenemos

$$P(N_1 \cap R_2 \cap B_3 \cap N_4) = P(N_1) \cdot P(R_2/N_1) \cdot P(B_3/R_2 N_1) \cdot P(N_4/B_3 R_2 N_1)$$

$$\gamma \quad P(N_1) = \frac{1}{2}, \quad P(R_2/N_1) = \frac{1}{3}, \quad P(B_3/R_2 N_1) = \frac{1}{4}, \quad P(N_4/B_3 R_2 N_1) = \frac{4}{7}$$

de aquí

$$P(N_1 \cap R_2 \cap B_3 \cap N_4) = \frac{1}{2} \cdot \frac{1}{3} \cdot \frac{1}{4} \cdot \frac{4}{7} = \frac{1}{42}.$$

EL TEOREMA DE LA PROBABILIDAD TOTAL Y LA FÓRMULA DE BAYES

Supongamos que en el espacio de probabilidad $(\Omega, \mathcal{A}, P)$, la familia $\{A_i\}_{i=1}^n$ constituye una partición del espacio muestral. Es decir

$$\Omega = \bigcup_{i=1}^n A_i \quad y \quad A_i \cap A_j = \emptyset, \quad i \neq j$$

La familia además, es finita o infinita numerable. Supongamos además que los sucesos que componen la partición son tales que $P(A_i) > 0, \forall i$. Sea ahora B un suceso cualquiera, entonces que

$$B = B \cap \Omega = B \cap \left(\bigcup_{i=1}^n A_i \right) = \bigcup_{i=1}^n (B \cap A_i)$$

tomando probabilidades y por la 5-aditividad

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

pero sabemos que $P(B/A_i) = \frac{P(B \cap A_i)}{P(A_i)} \rightarrow P(B \cap A_i) = P(B/A_i) \cdot P(A_i)$, sustituyendo

(12)

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

Fórmula que es conocida con el nombre de Fórmula de la probabilidad total. Comprobemos su utilidad.

Ejemplo.- La urna 1 contiene 2 bolas rojas, la urna 2 contiene una bola roja y 2 blancas y la urna 3 contiene tres bolas rojas y tres bolas blancas. Se lanza un dado, si sale 1, 2 o 3 seleccionamos la urna 1, si sale un 4 seleccionamos la urna 2 y con 5 o 6 seleccionamos la 3. Extraemos una bola de la urna seleccionada. Probabilidad de que sea blanca.

Sean $A \rightarrow$ la bola extraída es blanca

$U_i \rightarrow$ la urna elegida es la i , $i=1, 2, 3$.

$$P(A) = \sum_{i=1}^3 P(A \cap U_i) = \sum_{i=1}^3 P(A/U_i) \cdot P(U_i)$$

$$\gamma \quad P(A/U_1) = 0, \quad P(U_1) = \frac{1}{2}$$

$$P(A/U_2) = \frac{2}{3}, \quad P(U_2) = \frac{1}{6}$$

$$P(A/U_3) = \frac{1}{2}, \quad P(U_3) = \frac{1}{3}$$

Finalmente

$$P(A) = 0 \cdot \frac{1}{2} + \frac{2}{3} \cdot \frac{1}{6} + \frac{1}{2} \cdot \frac{1}{3} = \frac{1}{9} + \frac{1}{6} = \frac{5}{18}.$$

Una consecuencia inmediata de la fórmula que acabamos de obtener es otra conocida fórmula de probabilidad en el desarrollo de la teoría de la probabilidad o más exactamente, en una manera conceptual de la misma.

Bajo las mismas condiciones antes dadas, supongamos además que B es tal que $P(B) > 0$. Entonces

$$P(A_i/B) = \frac{P(A_i \cap B)}{P(B)} = \frac{P(B/A_i) \cdot P(A_i)}{\sum_{i=1}^n P(B/A_i) \cdot P(A_i)}, \quad \forall i$$

Esta fórmula es conocida como la FÓRMULA DE BAYES. Su importancia radica en que aprovecha la información conocida para modificar las probabilidades de los sucesos. De hecho, si observamos la fórmula se ella representamos convenientemente las probabilidades $P(A_i)$ y $P(B/A_i)$, $\forall i$. Podemos suponer que B es un suceso que tiene lugar bajo diversas condiciones, respecto a cuya naturaleza podemos establecer una serie de hipótesis, A_i . Las probabilidades $P(B)$ se denominan probabilidades a priori. Porque llevamos a cabo el experimento o suceso B y el conocimiento de este hecho nos permite obtener $P(A_i/B)$, conocida como probabilidades a posteriori, que conjetan las $P(A_i)$ a la luz de la información puntual adquirida (conocimiento del resultado del experimento). Veamos un ejemplo.

Ejemplo.- Llevamos nuevamente a la urna del ejemplo anterior. Calculamos $P(U_i/A)$, $i=1, 2, 3$

$$P(U_1/A) = \frac{P(A/U_1) \cdot P(U_1)}{\sum_{i=1}^3 P(A/U_i) \cdot P(U_i)} = 0$$

$$P(U_2/A) = \frac{\frac{3}{5} \cdot \frac{1}{2}}{\frac{5}{18}} = \frac{2}{5}, \quad P(U_3/A) = \frac{\frac{1}{2} \cdot \frac{1}{3}}{\frac{5}{18}} = \frac{3}{5}$$

(13)

Obsérvese que al saber que la bola extraída es blanca la probabilidad de que sea una de las bolas 2 o la 3 se han modificado y en concreto han mejorado por cuanto.

Bola	A priori	A posteriori
2	$\frac{1}{6}$	$\frac{2}{5}$
3	$\frac{1}{3}$	$\frac{3}{5}$

La probabilidad de elegir la bola 1 ~~se~~ ^{y como} se alcanza ~~por~~ ^{por} dicho suceso una vez que se sabe que la bola es blanca, vale 0 (se conoce en algo imposible de ocurrir).

La importancia de la fórmula de Bayes, intuitiva, estriba en este hecho: Siempre que poseamos información a priori del experimento nos permite acercarnos para modificar adecuadamente las probabilidades que maneja.

INDEPENDENCIA DE SUCESOS

Supongamos una urna con 10 bolas, 6 de ellas rojas y 4 blancas. Hacemos a cabo dos extracciones, con reemplazamiento, sean A_1 y A_2 los sucesos, "obtener bola roja en la primera y la segunda extracción" respectivamente. Sabemos que $P(A_1) = \frac{6}{10}$, $P(A_2) = \frac{6}{10}$ y además, $P(A_2/A_1) = \frac{6}{10} = P(A_2)$. Es decir, el conocimiento de lo que ocurrió en la primera extracción no de ninguna utilidad a la hora de saber que pasará en la segunda. Decimos, ante una situación como la presente, que ambos sucesos son independientes.

Este ejemplo nos ayudará mejor a comprender el por qué de la siguiente definición.

Definición 1. Sean A y B sucesos del espacio de probabilidad $(\Omega, \mathcal{F}, P)$, tal que $P(A) > 0$. Decimos que A y B son independientes si $P(B/A) = P(B)$.

Obsérvese que si además $P(B) > 0$, entonces

$$P(A/B) = \frac{P(A \cap B)}{P(B)} = \frac{P(B/A) \cdot P(A)}{P(B)} = \frac{P(B) \cdot P(A)}{P(B)} = P(A)$$

La independencia es una relación mutua entre los sucesos. Señalamos que el transcurso de la combinación anterior, como resultado intermedio, hemos obtenido la siguiente propiedad:

Propiedad 1. Si A y B son independientes, entonces $P(A \cap B) = P(A) \cdot P(B)$.

Como en ocasiones que muchos autores incluyen los términos de este párrafo y dan como definición la propiedad, denotamos como propiedad la que hemos presentado como definición.

Definición 2. Dos sucesos A y B del espacio de probabilidad $(\Omega, \mathcal{F}, P)$ decimos que son independientes si $P(A \cap B) = P(A) \cdot P(B)$

Es igual y si $P(A) > 0$, $P(B/A) = \frac{P(B \cap A)}{P(A)} = \frac{P(B) \cdot P(A)}{P(A)} = P(B)$. Propiedad 2

Esta segunda definición tiene la ventaja de no exigir condición alguna a los sucesos A y B . (14)
Así, mientras sucesos A y B con $P(A) = 0$ o $P(B) = 0$ no permiten una definición correcta de la probabilidad condicional, ello no impide la definición de independencia que acabamos de dar.

TEOREMA. Si A y B son independientes también lo son A y B^c , A^c y B o A^c y B^c .

Demostración. - Inmediata.

Conviene señalar que los conceptos de independencia e incompatibilidad no deben ser confundidos. De hecho, cuando dos sucesos incompatibles A y B son tales que $P(A) > 0$ y $P(B) > 0$, ambos son independientes por cuanto $P(A \cap B) = P(\emptyset) = 0$, mientras que $P(A) \cdot P(B) \neq 0$.

Ejemplo. - Empezamos al azar una carta de una baraja de 52. Sea A , la carta extraída es un as y sea B , la carta extraída es una copa. Entonces

$$P(A) = \frac{4}{52} = \frac{1}{13}, \quad P(B) = \frac{13}{52} = \frac{1}{4}$$

$$P(A \cap B) = P(\text{extraer el as de copas}) = \frac{1}{52}$$

pero $P(A) \cdot P(B) = \frac{1}{13} \cdot \frac{1}{4} = \frac{1}{52} = P(A \cap B)$, luego ambos sucesos son independientes.

La definición puede generalizarse para un número finito de sucesos, pero hay entonces que introducir un matiz en la misma.

Definición. - Sean $\{A_1, \dots, A_n\}$ una familia finita de sucesos del espacio de probabilidad $(\Omega, \mathcal{F}, P)$

a) Decimos que son mutuamente o colectivamente independientes si se verifican

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot \dots \cdot P(A_{i_k})$$

$$k = 2, \dots, n \quad \{i_1, \dots, i_k\} \subset \{1, 2, \dots, n\}$$

b) Decimos que son independientes dos a dos si

$$P(A_i \cap A_j) = P(A_i) \cdot P(A_j) \quad i, j = 1, \dots, n, \quad i \neq j$$

Obsérvese que la independencia mutua exige que se cumplan

$$\binom{n}{2} + \binom{n}{3} + \dots + \binom{n}{n} = 2^n - \binom{n}{1} - \binom{n}{0} = 2^n - n - 1$$

relaciones entre los n sucesos, $A_1, \dots, A_n$. Además, de la definición se sigue de inmediato que esta independencia implica la independencia dos a dos. Por el contrario, el contraejemplo que damos a continuación demuestra que no es cierta la implicación contraria.

Ejemplo. - Supongamos un tetraedro cuyos caras están pintadas, una de rojo, otra de azul, otra de verde y la cuarta con los tres colores. Sean

$A \rightarrow$	la cara sobre la que se apoya el tetraedro presenta color rojo		
$B \rightarrow$	id.	id.	azul
$C \rightarrow$	id.	id.	verde

Si el triángulo está bien construido, tendremos

$$P(A) = P(B) = P(C) = \frac{1}{2}$$

$$P(AB) = \frac{1}{4} = P(A) \cdot P(B)$$

$$P(AC) = \frac{1}{4} = P(A) \cdot P(C)$$

$$P(BC) = \frac{1}{4} = P(B) \cdot P(C)$$

pero $P(ABC) = \frac{1}{4} \neq P(A) \cdot P(B) \cdot P(C)$ y no hay independencia mutua.

Independencia entre σ -álgebras.- El concepto de independencia puede hacerse extensivo a los σ -álgebras en lugar de eventos tan solo a los sucesos. Así, para un espacio de probabilidad $(\Omega, \mathcal{A}, P)$ supongamos que existen dos σ -álgebras, subfamilias de $\mathcal{A}$ con estructura de σ -álgebra. Decimos que los σ -álgebras $\mathcal{A}_i$, $i=1, \dots, n$ son independientes si

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2) \cdot \dots \cdot P(A_n), \quad \forall A_i \in \mathcal{A}_i, \quad i=1, \dots, n.$$

El problema de la independencia trata de sucesos como de σ -álgebras se sitúa en el contexto de espacio medible producto y la definición sobre ellos de medida, a partir de los espacios coordenados, y que son medidas, como medidas, producto. En cualquier caso este problema resurge, naturalmente, los límites de este curso y no nos ocuparemos de él.

APENDICE . EL TEOREMA DE EXTENSION

Supongamos el espacio medible (R, β) (la recta real provista de la tribu de Borel). Para cada intervalo I , definimos

$$P(I) = \int_I \frac{1}{\pi} \cdot \frac{1}{1+x^2} dx.$$

La función de conjunto así definida verifica:

$$a) P(I) \geq 0, \quad \forall I \in \beta$$

$$b) P(R) = 1$$

$$c) \text{ Dado } \{I_j\}_{j=1}^n \text{ en } I_i \cap I_j = \emptyset, \quad i \neq j, \text{ entonces}$$

$$P\left(\bigcup_{j=1}^n I_j\right) = \sum_{j=1}^n P(I_j).$$

Podemos decir que P es una función de conjunto que se asemeja mucho a una medida de probabilidad, pero no lo es por ahora:

$$a) \text{ No sabemos si } P \text{ es } \sigma\text{-aditiva}$$

$$b) \text{ La hemos definido sobre los intervalos de } R \text{ que con una subfamilia de } \beta, \text{ pero no sobre } \beta.$$

En realidad a) se deduce por las propiedades de la integral nos permiten afirmar que la σ -aditividad (para intervalos) también va a verificarse. El mismo problema lo plantea la prueba

(15)

de extensión de P desde la familia de intervalos a la tribu de Borel. Este es un problema común a la construcción de medidas, y tiene una adecuada respuesta en la teoría de la medida. Es muy sencillo, en esencia, definir una función de conjunto sobre una familia de σ -álgebra con alguna característica especial. Por ejemplo, sobre la familia de intervalos de la forma $[a, b]$, ~~un punto o infinito, pero no simultáneamente~~, podemos definir una función real que $\mu([a, b]) = b - a$, ~~o sea $\mu([a, b]) = b - a$ si $a < b$ y 0 si $a = b$~~ , ni consideramos además intervalos de la forma $]-\infty, b]$, $[a, +\infty[$ y añadamos R y $\emptyset$ y definimos $\mu(]-\infty, b]) = +\infty$, $\mu([a, +\infty[) = +\infty$, $\mu(R) = +\infty$, $\mu(\emptyset) = 0$. Esta función es la que dará lugar a la medida de Lebesgue sobre esta tribu. Pero, ¿cómo?

La familia de intervalos que acabamos de considerar tiene dos características, a saber:

1) La σ -álgebra que engendra a la tribu de Borel.

2) Puede engendrar una estructura intermedia, llamada álgebra de conjuntos y que define la σ -álgebra en que se sitúa tan solo para uniones finitas, de manera sencilla. De hecho, ~~la tribu de Borel~~ el álgebra $\mathcal{A}(I)$, ni por I designamos la familia de intervalos, o más exactamente por que

$$\text{Si } A \in \mathcal{A}(I), \quad A = \bigcup_{i=1}^n I_i \quad \text{con } I_i \cap I_j = \emptyset, \quad i \neq j.$$

3) Es fácil comprobar que la σ -álgebra que engendramos con $\mathcal{A}(I)$ y con I es la misma, a saber, la tribu de Borel.

La característica 2) nos permite extender de forma inmediata y natural cualquier función de conjunto definida sobre I a $\mathcal{A}(I)$, sin más que sumando $\mu(A) = \sum_{i=1}^n \mu(I_i)$. Observe que, así definida, μ verifica sobre $\mathcal{A}(I)$

$$a) \mu(A) \geq 0, \quad \forall A \in \mathcal{A}(I)$$

$$b) \mu(A \cup B) = \mu(A) + \mu(B) \quad \text{si } A \cap B = \emptyset$$

Llegados a este punto y una propiedad que μ verifica podemos aplicar un conocido teorema de extensión de la medida, o teorema de extensión de Halm-Carathéodory, que afirma que si sobre un álgebra $\mathcal{A}$ tenemos definida una medida μ que es σ -finita, esta puede extenderse a la σ -álgebra que $\mathcal{A}$ engendra, de manera única.

La demostración del teorema requiere profundos conocimientos de teoría de la medida. En consecuencia, no obstante, hacen referencia al mismo porque el punto de construcción de medida de probabilidad sobre el espacio medible (R, β) , que hemos presentado al comienzo del apéndice, es muy frecuente en teoría de la probabilidad y solo ahora sabemos que se trata de afirmar que P es una medida de probabilidad, porque el teorema de extensión nos asegura su definición sobre β .

Capítulo 3

Aplicaciones medibles. Variables aleatorias

APLICACIONES MEDIBLES. VARIABLES ALEATORIAS

APLICACIONES MEDIBLES. PROPIEDADES

Definición.- Sean $(\Omega, \mathcal{A})$ y $(\mathcal{X}, \beta)$ dos espacios medibles. Sea h una aplicación de Ω en $\mathcal{X}$, decimos que h es una aplicación medible si

$$\forall B \in \beta, h^{-1}(B) \in \mathcal{A}.$$

Leamos a continuación algunas propiedades de interés.

Proposición I.- Sea h una aplicación medible de $(\Omega, \mathcal{A})$ en $(\mathcal{X}, \beta)$ y g una aplicación medible de $(\mathcal{X}, \beta)$ en $(\mathcal{Z}, \mathcal{C})$, entonces $g \circ h$ es una aplicación medible.

Demostración.- En efecto, $\forall C \in \mathcal{C}$, tenemos $g^{-1}(C) \in \beta$ y por tanto $h^{-1}[g^{-1}(C)] \in \mathcal{A}$, pero

$$[g \circ h]^{-1}(C) = h^{-1}[g^{-1}(C)] \quad \text{y de aquí el resultado.}$$

Proposición II.- Sea h una aplicación medible entre los espacios medibles $(\Omega, \mathcal{A})$ y $(\mathcal{X}, \beta)$, entonces

- a) Definimos $\mathcal{A}_h = \{B, B \subset \mathcal{X} / h^{-1}(B) \in \mathcal{A}\}$. Entonces $\mathcal{A}_h$ es una σ -álgebra, a la que llamaremos σ -álgebra imagen de $\mathcal{A}$ por h y que tiene la propiedad de ser la mayor σ -álgebra (para la relación de orden de inclusión) que hace medible la función h (entre los espacios medibles $(\Omega, \mathcal{A})$ y $(\mathcal{X}, \mathcal{A}_h)$).
- b) Definimos $\beta_h = \{A, A \subset \mathcal{X} / A = h^{-1}(B) \text{ con } B \in \beta\}$. β_h es una σ -álgebra, la σ -álgebra engendrada por h a partir de β . Tiene la propiedad de ser la menor σ -álgebra con la que podemos dotar a $\mathcal{X}$ para que h sea medible (entre $(\Omega, \mathcal{A})$ y $(\mathcal{X}, \beta_h)$).

Demostración.- Es fácil comprobar que tanto $\mathcal{A}_h$ como β_h son σ -álgebras, por ejemplo, si

$$\{B_n\}_{n \in \mathbb{N}} \subset \mathcal{A}_h, \text{ entonces } h^{-1}(B_n) \in \mathcal{A}. \text{ En } \gamma \text{ de aquí } \bigcup_{n \in \mathbb{N}} h^{-1}(B_n) \in \mathcal{A}$$

pero

$$\bigcup_{n \in \mathbb{N}} h^{-1}(B_n) = h^{-1}\left(\bigcup_{n \in \mathbb{N}} B_n\right), \text{ luego } \bigcup_{n \in \mathbb{N}} B_n \in \mathcal{A}_h.$$

Análogamente se comprueba para β_h (también las otras propiedades que definen el concepto de σ -álgebra. Por otra parte, de acuerdo con las definiciones de aplicación medible y la de $\mathcal{A}_h$, tenemos que

$$h: (\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \mathcal{A}_h) \quad \text{es medible}$$

pero si β tal que $h: (\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \beta)$ es medible, entonces $h^{-1}(B) \in \mathcal{A}, \forall B \in \beta$ luego $\beta \subset \mathcal{A}_h$ y esta es la mayor de cuantas hacen medible a h ($(\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \beta)$).

(1)

Revolviendo de forma análoga comprobaremos que β_h es la menor de las que hace medible h , cuando actúa entre $(\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \beta_h)$ y este último espacio medible es fijo. (2)

Proposición III.- 1) Sean $(\Omega, \mathcal{A})$ y $(\mathcal{X}, \beta)$ dos espacios medibles. Sea $\mathcal{C}$ una familia de partes de $\mathcal{X}$ tal que $\beta = \sigma(\mathcal{C})$. Una aplicación h entre Ω y $\mathcal{X}$ es medible si y sólo si,

$$\forall C \in \mathcal{C}, h^{-1}(C) \in \mathcal{A}.$$

[$\sigma(\mathcal{C})$, σ -álgebra engendrada por $\mathcal{C}$]

- 2) En particular, si $\mathcal{X}$ es un espacio topológico y si β es el tribu de Borel, h es medible si la imagen inversa de cualquier abierto es un elemento de $\mathcal{A}$.
- 3) Para espacios topológicos dotados de sus tribus de abiertos y de sus tribus de Borel respectivas, toda aplicación continua es medible.

Demostración.- 1) Si h es medible obviamente $h^{-1}(C) \in \mathcal{A}, \forall C \in \mathcal{C}$.

Recíprocamente, si $h^{-1}(C) \in \mathcal{A}, \forall C \in \mathcal{C}$, esto supone que $\mathcal{A}_h$, de la proposición anterior, contiene a $\mathcal{C}$ y por tanto contendrá a la σ -álgebra que se engendra, es decir, $\beta \subset \mathcal{A}_h$, pero esto supone que $h^{-1}(B) \in \mathcal{A}, \forall B \in \beta$, y h será medible.

2) Se deduce inmediatamente de 1)

3) Se deduce del hecho de que las aplicaciones continuas califican que las imágenes de abiertos son abiertos.

FUNCIONES MEDIBLES. PROPIEDADES

Definición.- Una función medible es una aplicación medible, f , entre el espacio medible $(\Omega, \mathcal{A})$ y $(\mathbb{R}, \beta)$, donde $\mathcal{A}$ es la recta real y β la tribu de Borel correspondiente.

Enunciamos a continuación algunas propiedades cuyas demostraciones omitiremos por escapar de las posibilidades y pretensiones de este curso. En cualquier caso entenderán también, presente por el uso posterior que de ellas hagamos.

Propiedades.- 1) La suma de funciones medibles, si está definida, es también medible.

2) El producto de funciones medibles es medible, si está definido.

3) Los supremos e ínfimos de funciones medibles son medibles.

Estas 3 propiedades al menos de funciones al que hacemos referencia son finito y, obviamente, todo ello, está definido sobre el mismo espacio medible $(\Omega, \mathcal{A})$.

4) El lim, lim y lim (cuando existe) de una sucesión de funciones medibles es también una función medible.

Las funciones medibles admiten una caracterización al margen de la definición dada y es:

Caracterización de las funciones medibles: Una función f , de $(\Omega, \mathcal{A})$ en $(\mathbb{R}, \beta)$ es medible si y sólo si la imagen de la forma $\{w; f(w) \leq a\} \in \mathcal{A}, \forall a \in \mathbb{R}$.

ALGUNAS FUNCIONES MEDIBLES DE INTERÉS

- 1) Función constante. Sea $f: \Omega \rightarrow \mathbb{R}$ tal que $f(\omega) = k, \forall \omega \in \Omega$. Esta función es medible observemos que los conjuntos de la forma $\{\omega; f(\omega) \leq a\}$ son

$$\{\omega; f(\omega) \leq a\} = \begin{cases} \emptyset, & \text{si } a < k \\ \Omega, & \text{si } a \geq k \end{cases}$$

y por tanto, como $\emptyset$ y Ω son elementos de $\mathcal{B}$, f es medible.

- 2) Función característica de un conjunto. Sea $A \subset \Omega$, definimos $f_A: \Omega \rightarrow \mathbb{R}$ mediante

$$f_A(\omega) = \begin{cases} 1, & \text{si } \omega \in A \\ 0, & \text{si } \omega \notin A \end{cases}$$

La función así definida no siempre es medible si damos a Ω de una σ -álgebra, su medibilidad se ligará al conjunto al cual caracteriza. Señalemos, ante de comprobar la afirmación que acabamos de hacer, que se designan como conjuntos medibles a los elementos del σ -álgebra del espacio medible. Es decir, $(\Omega, \mathcal{B})$ medible, $A \in \mathcal{B}$, entonces A es un conjunto medible.

Proposición. - La función característica de un conjunto medible es medible.

Efecto, si A es medible, entonces

$$\{\omega; f_A(\omega) \leq a\} = \begin{cases} \emptyset, & a < 0 \\ A^c, & 0 \leq a < 1 \\ A, & a \geq 1 \end{cases}$$

y como todos ellos son medibles, entonces f_A es medible.

- 3) Función simple. Una función simple es una función medible con rango finito. Es decir

$$\forall \omega \in \Omega, f(\omega) \in \{a_1, \dots, a_n\}$$

La medibilidad de la función supone que $f^{-1}(\{a_i\}) = A_i \in \mathcal{B}, i=1, \dots, n$ y además los A_i constituyen una partición de Ω . A saber

$$\bigcup_{i=1}^n A_i = \Omega, \quad A_i \cap A_j = \emptyset, \quad i \neq j, \quad i, j = 1, \dots, n.$$

Esta propiedad origina una representación de f mediante las funciones características de los A_i . En efecto, fácilmente se comprueba que toda función simple puede representarse de la forma

$$f = \sum_{i=1}^n a_i f_{A_i}$$

Pero por otra parte observemos que una función s , definida mediante la expresión $\sum_{i=1}^n a_i f_{A_i}$ con $A_i = s^{-1}(\{a_i\})$ medible, es una función simple. Por lo que en ocasiones encontraremos la siguiente definición para las funciones simples

Definición. - Sea s una aplicación de $\Omega \rightarrow \mathbb{R}$, decimos que s es una función simple si $s = \sum_{i=1}^n a_i f_{A_i}$, donde los A_i constituyen una partición medible de Ω y $a_i \in \mathbb{R}, i=1, \dots, n$.

(3)

La importancia de las funciones simples quedará puesta de manifiesto más adelante. Ocupemos ahora de una función medible que nos sea generativa inmediata de la simple. (4)

- 4) Función discreta. Una función d , definida del espacio medible $(\Omega, \mathcal{B})$ en $(\mathbb{R}, \mathcal{B})$ decimos que es discreta si

$$d = \sum_{n \in \mathbb{Z}} a_n f_{A_n}, \quad \text{donde los } a_n \in \mathbb{R} \text{ y los } A_n \text{ constituyen una partición medible numerable de } \Omega.$$

Obviamente si la partición numerable la tomamos finita aparece la función simple como caso particular de las funciones discretas.

VARIABLES ALEATORIAS

Cuando estamos estudiando el experimento consistente en lanzar un dado repetidamente el suceso A_i , la cara que nos muestra el dado presenta i puntos, simplemente mediante el número $i, i=1, \dots, 6$. Los limitamos a decir, ha caído en 6, o ha caído en 2, etc... Qué tal, no seamos osados de ello, pero estamos pasando del mundo abstracto de los sucesos al mundo concreto de los números, mediante una aplicación que a cada cara le hace corresponder el número de puntos que contiene. Esta actuación es muy frecuente ya de hecho implícita en el tratamiento que damos a todos los procesos aleatorios. Nos permite, en definitiva, abandonar las abstracciones que los sucesos suponen y actuar en la vida real, medio en el que nos desenvolvemos con facilidad y cuyas propiedades hemos estudiado exhaustivamente.

No obstante este cambio de escenario no puede llevarse a cabo de cualquier manera. Parece lógico pensar que la aplicación que nos trasladó de Ω a $\mathbb{R}$ goce de unas mínimas propiedades que garanticen el manejo de los conjuntos de los sucesos de la misma forma en que manejábamos a estos. Sin embargo que dicha aplicación conserve la estructura que poseíamos sobre Ω , por ejemplo, y puesto que la única estructura que allí tenemos es la σ -álgebra de sucesos, lo natural es tomar diciendo que la aplicación sea una función medible. De aquí la definición

Definición. - Una variable aleatoria es una función medible definida sobre un espacio de probabilidad.

Es costumbre designar las variables aleatorias mediante las letras mayúsculas $X, Y, Z, \dots$. Así pues, si X es una variable aleatoria (v.a.), tenemos

$$X: \Omega \rightarrow \mathbb{R}, \quad \text{además } X^{-1}(B) \in \mathcal{B}, \text{ con } B \in \mathcal{B}, \text{ de la tribu de sucesos.}$$

Así, cada suceso se le asocia, mediante X , en la imagen inversa de un conjunto del σ -álgebra, en definitiva en un subconjunto de $\mathbb{R}$.

Ejemplo. - Consideremos el experimento consistente en lanzar una moneda. El espacio muestral Ω está constituido por $\Omega = \{\text{cara}, \text{cruz}\}$

podemos definir $X: \Omega \rightarrow \mathbb{R}$ mediante $X(\{\text{cara}\}) = 1, X(\{\text{cruz}\}) = 0$. X es una variable aleatoria.

Ejemplo. - Lanzamos un dado dos veces consecutivas y estamos interesados en la suma de puntos que sus caras presenten. El espacio muestral está constituido por

$$\Omega = \{(i, j), i=1, \dots, 6, j=1, \dots, 6\} \quad i, j \text{ representan los puntos que muestran la primera y la segunda cara, repetitivamente}$$

Definimos sobre Ω la aplicación

$$X(\omega) = i+j, \quad \omega \in \Omega, \quad \omega = (i,j), \quad i,j = 1, \dots, 6$$

Esta aplicación es una aplicación medible y por tanto una variable aleatoria. Más concretamente se trata de una función simple por estar su rango \$s\$ finito, a saber \$\{2, 3, \dots, 12\}\$, los posibles valores que pueden obtenerse. Si denominamos \$S_d\$ al conjunto de puntos que constituyen el rango de \$X\$, tendríamos que para cualquier conjunto de \$\mathcal{B}(\mathbb{N})\$, \$B\$

$$X^{-1}(B) = \emptyset, \quad \text{si } B \cap S_d = \emptyset$$

$$\text{Si } B \cap S_d = \{a_1, \dots, a_k\}, \text{ entonces}$$

$$X^{-1}(B) = \{(i,j) = \omega \in \Omega / i+j = a_e, e=1, \dots, k\}$$

conjunto que evidentemente es un suceso por estar comprendido en la \$\sigma\$-álgebra de los partes.

$$\text{Por ejemplo, si } B \cap S_d = \{8\}, \text{ tendríamos } X^{-1}(B) = \{(2,6), (6,2), (3,5), (5,3), (4,4)\}.$$

Probabilidad inducida. Sobre el espacio de probabilidad \$(\Omega, \mathcal{B}, P)\$ tenemos una medida de probabilidad

\$P\$ que nos permite determinar la probabilidad de cualquier suceso. Mediante la variable aleatoria \$X\$ vamos trasladando nuestra atención a \$(R, \mathcal{B})\$ y requeriremos de una medida de probabilidad que nos permita determinar la probabilidad de cualquier conjunto de \$\mathcal{B}(\mathbb{N})\$, lo tanto en concreto representa la transformación de algún suceso o conjunto de sucesos del espacio muestral. Veamos como hacerlo.

Sea \$B \in \mathcal{B}\$ notemos que \$X^{-1}(B) \in \mathcal{B}\$, vamos a definir sobre \$\mathcal{B}\$ la siguiente aplicación

$$\forall B \in \mathcal{B}, \quad P'(B) = P(X^{-1}(B)).$$

Esta aplicación está constantemente definida sobre todos los elementos de \$\mathcal{B}\$ y además:

$$I) \quad P'(\emptyset) = P(X^{-1}(\emptyset)) = P(\emptyset) = 0.$$

$$II) \quad P'(B) \geq 0, \quad \forall B \in \mathcal{B}.$$

$$III) \quad \{B_n\}_{n \geq 1} \subset \mathcal{B}, \quad B_n \cap B_m = \emptyset, \quad n \neq m, \quad P'(\bigcup_{n \geq 1} B_n) = P(X^{-1}(\bigcup_{n \geq 1} B_n)) = P(\bigcup_{n \geq 1} X^{-1}(B_n))$$

y por las propiedades de \$P\$ y de la imagen inversa,

$$P'(\bigcup_{n \geq 1} B_n) = \bigcup_{n \geq 1} P(X^{-1}(B_n)) = \bigcup_{n \geq 1} P'(B_n)$$

$$IV) \quad P'(R) = P(X^{-1}(R)) = P(\Omega) = 1$$

\$P'\$ es pues una probabilidad sobre \$R\$, más exactamente sobre la \$\sigma\$-álgebra de \$\mathcal{B}(\mathbb{N})\$, a la que denominamos probabilidad inducida y que actúa trasladando \$P\$ sobre \$\mathcal{B}\$ mediante \$X\$.

Ejemplo. - Del ejemplo anterior, si \$B \cap S_d = \{8\}\$, \$P'(B) = P(X^{-1}(B)) = P(\{(2,6), (6,2), (3,5), (5,3), (4,4)\})\$ y si el dado es equilibrado, la probabilidad se obtendrá mediante la fórmula de Laplace y de aquí

$$P'(B) = \frac{5}{36}.$$

⑤ Observación. Obsérvese que la probabilidad inducida es sólo característico de la variable aleatoria que la define. ⑥

No se observa que en ocasiones sea denique mediante \$P'_X\$, no haber ni existe uso de conjuntos por el manejo simultáneo de varias variables aleatorias. Partiendo de un mismo espacio de probabilidad, distintas variables aleatorias dan lugar a distintas probabilidades inducidas, veámoslo mediante un ejemplo.

Sobre el espacio muestral \$\Omega = \{(i,j), i,j=1, \dots, 6\}\$ de los posibles resultados obtenidos al lanzar dos veces un dado (o una vez dos dados), definimos la v.a. \$X\$ como antes lo hicimos y una nueva v.a. \$Y\$, como sigue

$$Y(\omega) = |i-j|, \quad \omega = (i,j), \quad i,j=1, \dots, 6.$$

Consideremos un mismo conjunto de \$\mathcal{B}(\mathbb{N})\$, \$B = \{2\}\$, entonces

$$P'_X(B) = P(X^{-1}(\{2\})) = P(\{(4,1)\}) = \frac{1}{36}$$

$$P'_Y(B) = P(Y^{-1}(\{2\})) = P(\{(1,3), (3,1), (2,4), (4,2), (3,5), (5,3), (4,6), (6,4)\}) = \frac{8}{36}.$$

Función de distribución de una variable aleatoria. Mediante \$P'\$, probabilidad inducida por \$X\$, podemos definir

una función de \$R\$ en \$R\$ con unas propiedades muy interesantes.

$$\text{para } x \in R, \text{ definimos } F_X(x) = P'([-\infty, x]) = P(X^{-1}([-\infty, x])) = P(X \leq x).$$

Esta función tiene las siguientes propiedades

$$F.1) \quad \text{Si } x_1 \leq x_2, \text{ entonces } [-\infty, x_1] \subset [-\infty, x_2] \text{ y por la monotonía de } P'$$

$$P'([-\infty, x_1]) \leq P'([-\infty, x_2]) \rightarrow F_X(x_1) \leq F_X(x_2)$$

la función \$F_X\$ monótona creciente.

$$F.2) \quad \text{Sea } x \text{ un punto cualquiera de } R. \text{ Consideremos la siguiente familia de intervalos}$$

$$\{[-\infty, x_n], n \geq 1, x_1 \leq x_2 \leq x_3 \leq \dots, x_n \rightarrow x\}$$

que constituye una familia monótona creciente de intervalos. Supongamos además que la sucesión de los \$x_n\$ converge a \$x\$, entonces \$\lim_{n \rightarrow \infty} [-\infty, x_n] = \bigcap_{n \geq 1} [-\infty, x_n] = [-\infty, x]\$. Por las propiedades de continuidad de \$P'\$, tenemos

$$P'([-\infty, x]) = P'(\bigcap_{n \geq 1} [-\infty, x_n]) = \lim_{n \rightarrow \infty} P'([-\infty, x_n])$$

y entendimos de la función que acabamos de definir

$$F_X(x) = \lim_{n \rightarrow \infty} F_X(x_n) \quad x_n \uparrow x,$$

y dada la monotonía de \$F_X\$ esto supone que \$F_X\$ es continua por la derecha.

Estas dos propiedades caracterizan a \$F_X\$ como una función de distribución, pero por otra parte que la hacen especialmente interesante.

F3) Si $\{x_n\}_{n \in \mathbb{N}}$ es una sucesión de números racionales que ~~tende~~ ^{tende} a $- \infty$ y además $x_n > x_{n+1}$ entonces los $I_n =]- \infty, x_n]$ constituyen una sucesión monótona decreciente tal que

$$\bigcap_{n \in \mathbb{N}} I_n = \emptyset$$

aplicando la continuidad de Φ de P' ,

$$\lim_n P'(I_n) = 0, \text{ pero } P'(I_n) = F_X(x_n).$$

En definitiva, dada la monotonía de F , podemos afirmar

$$\lim_{x \rightarrow -\infty} F_X(x) = 0.$$

F4) Razonando análogamente para una sucesión monótona de x_n que tiende a $+\infty$, podemos afirmar que

$$\lim_{x \rightarrow +\infty} F_X(x) = 1.$$

Setenta pues de una función de distribución acotada por la unidad a la que se conoce como función de distribución de probabilidad de la variable aleatoria X .

Siendo P' una característica de X y siendo F_X derivada a partir de P' , obviamente, así tenemos una característica de la variable aleatoria que la origina. El interés de P' y F_X reside en que ambos conceptos permiten conocer la variable aleatoria que los ha originado. Este interés "conocer" adquiere poder determinar la probabilidad de que la variable aleatoria tome valores en cualquier conjunto de poner. Conocer esto de una variable aleatoria es saberlo todo de la misma.

Continuemos estudiando las propiedades de F_X . Hemos afirmado que la función era continua por la derecha, veamos ahora que sigue cuando tratamos de calcular su continuidad por la izquierda. Dada la monotonía de F_X bastará que trabajemos con sucesiones monótonas.

Sea $\{x_n\}_{n \in \mathbb{N}}$ una sucesión monótona ~~creciente~~ ^{decreciente} que converge a x , ello supone que los $I_n =]- \infty, x_n]$ constituyen una sucesión monótona creciente de intervalos tales que

$$\lim_n I_n = \bigcup_n I_n =]- \infty, x],$$

definamos una nueva familia de intervalos, $I'_n = I - I_n =]x_n, x]$, estos constituyen una familia monótona decreciente cuyo límite es

$$\lim_n I'_n = \bigcap_n I'_n = \{x\},$$

tomando probabilidades,

$$\begin{aligned} P'(\lim_n I'_n) &= P'(\{x\}) = \lim_n P'(I'_n) = \lim_n P'(I - I_n) = \lim_n [P'(I) - P'(I_n)] = \\ &= \lim_n [F_X(x) - F_X(x_n)] = F_X(x) - \lim_n F_X(x_n). \end{aligned}$$

Podemos pues afirmar que

$$F_X(x) - F_X(x-0) = P'(\{x\}), \quad \forall x \in \mathbb{R}.$$

La continuidad por la izquierda no está garantizada, o, menos que $P'(\{x\}) = 0$. Directamente relacionada

con la discontinuidad que esto impone podemos enunciar el siguiente teorema

TEOREMA. - El número de discontinuidades (saltos) que presenta una función de distribución de probabilidad es a lo sumo numerable.

Demostración. - Sabemos que $0 \leq F_X(x) \leq 1, \forall x \in \mathbb{R}$. Tratamos de comparar que

$$F_X(x+0) - F_X(x-0) = P'(\{x\}),$$

viendo $P'(\{x\})$ la magnitud de la discontinuidad.

F_X no puede tener más de un salto (discontinuidad) con magnitud mayor que $\frac{1}{2}$, ni más de tres cuyos magnitudes estén comprendidas entre $\frac{1}{4}$ y $\frac{1}{2}$. En general el número de saltos cuyos magnitudes estén comprendidas entre $\frac{1}{2^n}$ y $\frac{1}{2^{n-1}}$ no puede superar a 2^{n-1} . De donde con ello en número total (unión numerable de cantidades finitas) así a lo sumo numerable.

El conjunto de puntos de discontinuidad de la función de distribución de una variable aleatoria juega un importante papel en la caracterización de ésta y sobre ello volveremos más tarde.

Señalamos finalmente la utilidad de la función de distribución de probabilidad a la hora de determinar la probabilidad de un intervalo de la forma $]x_1, x_2]$. En efecto, dada su definición

$$F_X(x) = P'([-\infty, x])$$

y teniendo en cuenta que

$$]x_1, x_2] =]-\infty, x_2] -]-\infty, x_1]$$

y que

$$P'([x_1, x_2]) = P'([-\infty, x_2] -]-\infty, x_1]) = P'([-\infty, x_2]) - P'([-\infty, x_1]) = F_X(x_2) - F_X(x_1).$$

Mención de una medida de probabilidad a partir de una función de distribución de probabilidad.

En el párrafo precedente hemos visto que partiendo del espacio de probabilidad $(\mathbb{R}, \mathcal{B}, P')$ se define una función cuyos propiedades se han puesto de manifiesto y cuya principal característica es la de ser una función de distribución tal y como se entiende en el Análisis Matemático clásico.

Observemos la validez del desarrollo independientemente del origen de P' . Es decir, con cualquier medida de probabilidad definida inicialmente sobre los borelianos de $\mathbb{R}$ habremos llegado a una función de características similares.

Un importante aspecto de este proceso, quizás el más relevante, es que puede invertirse. A saber, partiendo de una función de distribución debidamente normalizada podemos definir sobre $\mathbb{R}$ una medida de probabilidad. Veamos cómo.

Sea F una función de distribución, es decir

$$P.1) \text{ Si } x_1 \leq x_2 \rightarrow F(x_1) \leq F(x_2)$$

$$P.2) \text{ } F \text{ es continua por la derecha}$$

además verifica

$$P.3) \lim_{x \rightarrow -\infty} F(x) = 0$$

$$P.4) \lim_{x \rightarrow +\infty} F(x) = 1,$$

lo que se conoce como función de distribución de probabilidad.

Consideremos ahora la siguiente familia de intervalos

$$\mathcal{Z} = \{ \emptyset, R,]-\infty, x],]x, y],]x, +\infty[\}$$

y definamos sobre ella la siguiente función de conjuntos

$$P(\emptyset) = 0, \quad P(]x, y]) = F(y) - F(x), \quad P(]-\infty, x]) = F(x) - \lim_{x \rightarrow -\infty} F(x) = F(x)$$

$$P(]x, +\infty[) = \lim_{x \rightarrow +\infty} F(x) - F(x) = 1 - F(x), \quad P(R) = \lim_{x \rightarrow +\infty} F(x) - \lim_{x \rightarrow -\infty} F(x) = 1.$$

La familia $\mathcal{Z}$ posee además, dos interesantes propiedades:

2.1) La sigma-álgebra que engendra, $\sigma(\mathcal{Z})$ es la tribu de Borel

2.2) El algebra que engendra, $\mathcal{A}(\mathcal{Z})$, coincide

$$\forall T \in \mathcal{A}(\mathcal{Z}), \quad T = \bigcup_{i=1}^n I_i, \quad I_i \in \mathcal{Z}, \quad I_i \cap I_j = \emptyset.$$

Esta última propiedad nos permite extender P de $\mathcal{Z}$ a $\mathcal{A}(\mathcal{Z})$ de forma inmediata,

$$P(T) = \sum_{i=1}^n P(I_i)$$

con lo que P sobre $\mathcal{A}(\mathcal{Z})$ verifica

a) Es no negativa, $P(T) \geq 0, \forall T \in \mathcal{A}(\mathcal{Z})$

b) Es aditiva, $\forall T_1, T_2 \in \mathcal{A}(\mathcal{Z}), \text{ con } T_1 \cap T_2 = \emptyset, P(T_1 \cup T_2) = P(T_1) + P(T_2).$

En estas condiciones podemos aplicar el teorema de extensión de Kolmogoroff y definir sobre $\mathcal{R}$ una medida de probabilidad, pues $P(R) = 1$, que resulta ser la extensión, única, de la inicialmente definida sobre $\mathcal{Z}$ y $\mathcal{A}(\mathcal{Z})$.

Queda así puesta en evidencia la correspondencia biunívoca existente entre la medida de probabilidad que corresponde a una variable aleatoria y la función de distribución de probabilidad de la misma. La equivalencia que ello supone hace que sea más cómodo para nosotros trabajar con una u otra, utilizaremos henceforth con la más sencilla de manejar, la función de distribución.

Ejemplo: trabajemos nuevamente en el espacio muestral $\Omega = \{i \text{ (puntos en la cara del dado)}, i=1, \dots, 6\}$. mediante la aplicación

$$X: \{i \text{ (puntos en la cara del dado)}\} \rightarrow i$$

definimos una variable aleatoria y a partir de ella, P , en la forma ya conocida, siendo P la probabilidad definida sobre Ω . Estudiemos con un poco de detalle la función de distribución de X , F_X .

Sea $S_d = \{1, 2, 3, 4, 5, 6\}$, el rango de X . Tendremos

$$F_X(x) = 0, \quad \forall x < 1$$


para $x = i, i \in S_d$, tendremos

$$F_X(i) = P(X \leq i) = P\left\{j \text{ puntos en la cara del dado}, j \leq i\right\} = \sum_{j=1}^i \frac{1}{6} = \frac{i}{6}$$

para $x > 6$, tendremos

$$F_X(x) = P(X \leq x) = P(\Omega) = 1$$

(9)



La función de distribución obtenida en el lanzamiento de un dado, mediante la variable aleatoria que a cada lanzamiento corresponde el número de puntos que caiga.

Digamos finalmente algo sobre la continuidad de F_X . Recordemos que los puntos de discontinuidad de F_X son aquellos reales para los que,

$$x \in \mathcal{R}, \quad P'(x) = P(X=x) \neq 0.$$

En el caso que estudiamos ello sólo ocurre para $x \in S_d$, además, F_X presenta discontinuidades en $x \in \{1, 2, 3, 4, 5, 6\}$, todas ellas de igual magnitud, a saber

$$F_X(x+0) - F_X(x-0) = P(X=x) = \frac{1}{6}, \quad x=1, 2, 3, 4, 5, 6.$$

La función, como se pone de manifiesto en la gráfica, es continua en el complementario de S_d .

VARIABLES ALEATORIAS DISCRETAS

Definición: Sea $(\Omega, \mathcal{A}, P)$ un espacio de probabilidad, definimos sobre él una variable aleatoria X . Decimos que X es una v.a. discreta si el conjunto de valores de su rango, S_d , es a lo sumo numerable. La consecuencia inmediata de esta definición es que la variable X será de la forma

$$X = \sum_{i=1}^{\infty} x_i \cdot I_{A_i}, \quad \text{con } x_i \in S_d, \forall i \text{ y } A_i = X^{-1}(\{x_i\}) \in \mathcal{A}, \quad \bigcup_{i=1}^{\infty} A_i = \Omega, \quad A_i \cap A_j = \emptyset \quad (i \neq j)$$

es decir, resulta de lo que definimos en su momento como una función discreta.

Por otra parte la función de distribución de X , F_X , será una función de salto, o sea escalera, por cuanto

$$F_X(x) = 0, \quad \forall x < \min S_d = x_1, \quad [S_d = \{x_1, x_2, \dots, x_n, \dots\}, \text{ los } x_i \text{ son ordenados}].$$

$$F_X(x) = P(X \leq x) = P(X \in \{x_1, \dots, x_i\}) = \sum_{j=1}^i P(X=x_j) = \sum_{j=1}^i P(A_j), \quad x \in [x_i, x_{i+1}[.$$

Los puntos de discontinuidad de F_X son los de S_d y la magnitud de las discontinuidades en x_i es $P(A_i)$. La función de cuantía. Poseemos definir una nueva función, mediante X , que será muy útil para estudiar las propiedades de X .

Sea $f_X: \mathcal{R} \rightarrow \mathcal{R}$ definida mediante

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

a esta función se la denomina función de cuantía de la variable aleatoria X . En ocasiones se la denomina también función de probabilidad, puesto que proporciona, en cada punto, la probabilidad de que la v.a. X tome dicho valor. ¿Cuál es la propiedad de f_X ? ¿Cuál su relación, si la hay, con F_X ?

(10)

Si el punto x está comprendido entre $[i, i+1[$, $i \in S_d$, entonces

$$F_X(x) = P(X \leq x) = P\left\{j \text{ puntos en la cara del dado}, j \leq x\right\} = \sum_{j=1}^i \frac{1}{6} = \sum_{j=1}^i \frac{1}{6} = \frac{i}{6}.$$

De acuerdo con esto la gráfica de la función de distribución es la que presenta más. Es una gráfica en escalera, cuyos peldaños (tramos constantes) aparecen entre dos valores consecutivos de S_d , tal como hemos visto en la atención de F_X .

Propiedades de la función de cuantía:

1) $f_X(x) \geq 0, \forall x \in \mathbb{R}$

En efecto, si $x \in S_d$, $f_X(x) = f_X(x_i) = P(A_i)$, $x = x_i$

Si $x \in S_d^c$, $f_X(x) = P(X=x) = 0$.

2) $\sum_{x_i \in S_d} f_X(x_i) = 1$

$$\sum_{x_i \in S_d} f_X(x_i) = \sum_{x_i \in S_d} P(X=x_i) = \sum_{x_i \in S_d} P(A_i) = P\left(\bigcup_i A_i\right) = P(\Omega) = 1$$


3) $f_X(x) = P(X=x) = P'(x) = F_X(x+0) - F_X(x-0) = F_X(x) - F_X(x-0)$.

La tercera propiedad establece la relación existente entre ambas funciones y nos exactamente permite obtener la función de cuantía a partir de la función de distribución de la v.a. X . Pero el conocimiento de f_X permite también poseer en sentido contrario, entendemos para ello que

$$F_X(x) = P'(1-\infty, x) = P(X \leq x) = P(X \in S_d \cap]-\infty, x]) = P(X \in \{x_1, \dots, x_n\}, x_n \leq x) = \sum_{x_i \leq x} P(X=x_i) = \sum_{x_i \leq x} f_X(x_i).$$

lo que permite construir F_X a partir de f_X . Esto supone que las características probabilísticas de X , que conocemos a través de su distribución de probabilidad, es decir, F_X , pueden también conocerse mediante f_X y en ello estriba precisamente la importancia y utilidad de la función de cuantía.

Ejemplo. Considerando nuevamente el ejemplo del dado.



La función de cuantía valdrá cero en toda la recta real excepto en los puntos de $S_d = \{1, 2, 3, 4, 5, 6\}$. En dichos puntos la función vale

$$f_X(i) = P(X=i) = \frac{1}{6}, \quad i=1, 2, 3, 4, 5, 6.$$

La representación gráfica de f_X es la que se presenta.

Ejemplo. Supongamos una familia con 4 hijos y supongamos también que las probabilidades de nacimiento de varón o hembra son iguales e iguales a $1/2$. El espacio muestral de los posibles combinaciones de sexos entre los hijos de la familia está constituido por 16 puntos, a saber:

$$\Omega = \{VVVV, VVVH, VVHV, VHVH, HVVV, VVHH, \dots, HHHH\} \quad \begin{matrix} V - \text{varón} \\ H - \text{hembra} \end{matrix}$$

Denotamos a Ω de la familia de sus puntos y definimos sobre ella la medida de probabilidad discreta, de manera que $P(A) = \frac{n}{16}$, $n =$ número de puntos de A , $A \in \mathcal{A}$.

Sea ahora X una variable aleatoria definida mediante, $X: \Omega \rightarrow \mathbb{R}$, $X(\omega) = n = \#$ de varones en ω . La variable así definida será discreta y $S_d = \{0, 1, 2, 3, 4\}$. Vamos como con las funciones de cuantía, f_X y de distribución, F_X .

(11)

Función de cuantía: Ya sabemos que $f_X(x) = 0$, si $x \notin S_d$. Para $x = n$, $n = 0, 1, 2, 3, 4$, tenemos (12)

$$f_X(n) = P(X=n) = P(\text{hay } n \text{ varones en la familia}) = P(A_n)$$


el número de casos posibles es 16, mientras que los casos favorables serán los posibles decimos de n nacimientos (estados para los 4 que han ocurrido, es decir, $\binom{4}{n}$), así que

$$f_X(n) = P(A_n) = \binom{4}{n} \cdot \frac{1}{16} = \binom{4}{n} \left(\frac{1}{2}\right)^4 \cdot \left(\frac{1}{2}\right)^{4-n}, \quad n=0, 1, 2, 3, 4$$

constantemente

$$f_X(0) = \frac{1}{16}, \quad f_X(1) = \frac{1}{4}, \quad f_X(2) = \frac{6}{16}, \quad f_X(3) = \frac{1}{4}, \quad f_X(4) = \frac{1}{16}.$$

Función de distribución: Utilizando la relación existente entre f_X y F_X , tendremos:



$$F_X(x) = \sum_{x_i \leq x} f_X(x_i), \text{ así}$$

$$F_X(x) = 0, \quad \text{si } x < 0$$

$$F_X(x) = \frac{1}{16}, \quad \text{si } 0 \leq x < 1$$

$$F_X(x) = \frac{2}{16}, \quad \text{si } 1 \leq x < 2$$

$$F_X(x) = \frac{3}{16}, \quad \text{si } 2 \leq x < 3$$

$$F_X(x) = \frac{4}{16}, \quad \text{si } 3 \leq x < 4$$

$$F_X(x) = \frac{5}{16}, \quad \text{si } 4 \leq x < 5$$

$$F_X(x) = 1, \quad \text{si } x \geq 5.$$

Esta variable aleatoria es un caso particular de una familia de variables aleatorias a las que se conoce generalmente como variable aleatoria binomial y son muy útiles en el estudio de fenómenos que obedecen a un determinado esquema, el modelo binomial. De una y otra no suspensamos a intentar cuando stede- lues algunos con objetos de variables aleatorias discretas.

(12)

Capítulo 4

Variables aleatorias discretas

DISTRIBUCION DE BERNOULLI

(B-1)

Una prueba de Bernoulli es aquel experimento que tiene como resultado la verificación (éxito) o no (fracaso) de determinado suceso A. El espacio muestral consta de dos puntos, $w_1 = A, w_2 = A^c$. Podemos definir una variable aleatoria, de la forma

$$X(w_1) = 1, \quad X(w_2) = 0,$$

si $P(A) = p$ y $P(A^c) = 1 - p = q$, entonces esta variable aleatoria, que tomamos como v.a. de Bernoulli, tiene por función de densidad,

$$f_X(x) = p, \quad f_X(0) = q, \quad f_X(x) = 0, \quad \forall x \in \mathbb{R} - \{0, 1\}.$$

Es muy fácil comprobar que se trata de una función de densidad.

DISTRIBUCION BINOMIAL

Supongamos n pruebas de Bernoulli independientes, de manera que en cada una de ellas el resultado es éxito o fracaso y p y $q = 1 - p$ con, respectivamente, las probabilidades de éxito o fracaso en cada una de las pruebas. El espacio muestral de las n pruebas, Ω , está constituido por todas las posibles combinaciones de éxito y fracaso que pueden darse en las n pruebas, es decir

$$\Omega = \{w_1, \dots, w_n\} \quad \text{con, por ejemplo, } w_i = \underbrace{AAA \dots A}_n A^c, \quad A = \text{éxito}, \quad A^c = \text{fracaso}.$$

Entonces, ~~tenemos~~ ^{tenemos} que todos los puntos del espacio muestral son igualmente probables. ~~Es decir, que así~~ ^{Así}, por ejemplo, si w_i es un punto de Ω que comporta x éxitos y $n - x$ fracasos, tendremos

$$P(w_i) = p^x q^{n-x}.$$

Definamos, sobre Ω , la siguiente variable aleatoria

$$X(w_i) = n - \text{de éxitos que } w_i \text{ comporta},$$

se trata de una variable discreta y, concretamente, con un rango finito, a saber $S_d = \{0, 1, 2, \dots, n\}$. [Es costumbre también escribir $X = \{0, 1, \dots, n\}$, para designar el rango de la función]. A esta variable se la conoce como variable aleatoria Binomial. Estudiemos su función de densidad y veremos el porqué de tal nombre.

Ya sabemos que:

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

por tanto, si $x \in \mathbb{R} - S_d$, entonces $f_X(x) = 0$, pero para $x \in S_d$, tendremos

$$x \in S_d, \quad f_X(x) = P(X = x) = P(\{w_i, \text{tales que en } w_i \text{ hay } x \text{ éxitos}\}) = P(B)$$

sabemos que cada uno de los $w_i \in B$, tienen una probabilidad, $P(w_i) = p^x q^{n-x}$, pero, ¿cuántos hay? Los x éxitos pueden distribuirse de $\binom{n}{x}$ formas sobre los n individuos, así pues B contiene $\binom{n}{x}$ elementos, y en definitiva

$$f_X(x) = \binom{n}{x} p^x q^{n-x}, \quad x \in \{0, 1, \dots, n\}.$$

Efectivamente f_X es una función de densidad pues

$$a) \quad f_X(x) \geq 0, \quad \forall x \in \mathbb{R}$$

(B-2)

$$b) \quad \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n f_X(x) = \sum_{x=0}^n (p+q)^n = 1^n = 1.$$

El nombre de binomial se justifica al observar que los valores de la función de densidad son coeficientes del desarrollo del binomio $(p+q)^n$.

Es costumbre designar abreviadamente la distribución binomial de la manera $B(n, p)$, donde n y p son llamados parámetros de la distribución. Obsérvese que conocidos n y p la distribución binomial queda perfectamente determinada por cuanto conocemos el n.º de pruebas de Bernoulli que componen la experiencia y la probabilidad de éxito en cada una de ellas.

La v.a. Binomial se aplica en todas aquellas experiencias que cumplan en:

- la experiencia consta de un número finito de pruebas, independientes unas de otras.
- En cada prueba ocurre o no un determinado suceso (éxito o fracaso)
- la probabilidad de ocurrencia del suceso es la misma en cada prueba.

en estas condiciones la $B(n, p)$ describe adecuadamente la probabilidad de obtener x éxitos en la citada experiencia (o de obtener $n - x$ fracasos).

EJEMPLOS DE UTILIZACIÓN DE LA BINOMIAL

B-10

- I) Los dados de Weldon. Consideremos un experimento consiste en lanzar un dado 12 veces y sea "éxito" la aparición de un cinco o un seis. Con un dado perfecto la probabilidad de éxito viene dada por $p = \frac{1}{3}$ y el número de éxitos debería seguir una distribución Binomial $B(12, \frac{1}{3})$. Levamos a cabo el experimento un total de 26306 veces y recogemos en una tabla, reproducida parcialmente a continuación, las frecuencias, relativas observadas y las probabilidades teóricas. De su comparación (en su día usamos que los biólogos duplican para llevar a cabo) y teniendo en cuenta el elevado número de repeticiones, puede deducirse que los datos teóricos no se ajustan adecuadamente a los experimentales. Puede suponerse, a la luz de este resultado, que el dado utilizado presenta un pequeño sesgo a favor de la aparición del cinco o el seis, de tal manera que $p = 0.3377$ sería una más razonable probabilidad de éxito.

DATOS DEL DADO DE WELDON

k	$B(12, \frac{1}{3})$	Frecuencia observada	$B(12, 0.3377)$
3	0.211452	0.208127	0.207736
4	0.238446	0.232418	0.238324
5	0.190757	0.197445	0.194429
6	0.111235	0.115889	0.115660

- II) Supongamos que el número de "éxitos" en determinada experiencia sigue una ley binomial $B(n, 0.9)$, ¿cuántas repeticiones debemos llevar a cabo para asegurarnos que la probabilidad de al menos un éxito sea $\frac{1}{2}$ o más?

$$P(X \geq 1) = 1 - P(X=0) = 1 - (0.9)^n \geq \frac{1}{2}$$

y de aquí $-n \log(0.9) \geq \log 2$ lo que da $n \geq 70$

- III) Un problema de suministro eléctrico. Supongamos que $n=10$ trabajadores usan una fuente de energía eléctrica intermitentemente y estamos interesados en estimar la carga total esperada. Como una aproximación al problema imaginemos que en un momento determinado cada trabajador tiene la misma probabilidad p de necesitar utilizar una unidad de potencia. Si trabajan independientemente, la probabilidad de que exactamente k de ellos necesitan energía al mismo tiempo, vendrá dada por $B(n, p)$. Si por término medio, un trabajador utiliza

la fuente de energía 12 minutos por hora, $p = \frac{1}{5}$. La probabilidad de que siete o más trabajadores requieran corriente en el mismo momento vendrá dada por:

$$P(X \geq 7) = \sum_{x=7}^{10} \binom{10}{x} \left(\frac{1}{5}\right)^x \left(\frac{4}{5}\right)^{10-x} = 0.0008643584$$

En otras palabras, si la fuente de energía se ajusta a 6 unidades de potencia, la probabilidad de adecuación de uso será 0.00086.... lo que en términos de tiempo, tomando el minuto como unidad básica, que 1 de cada 1157 minutos podría ocurrir dicha adecuación, es decir 1 minuto cada 20 horas de uso. La probabilidad para 8 o más trabajadores utilizando la corriente al mismo tiempo es 0.000779264, es decir, unas 11 veces menor.

- IV) Contraste de sueros o vacunas. Supongamos que la incidencia normal de determinada enfermedad, en el ganado vacuno es 0.25. Para contrastar un suero descubierta recientemente se inyectan con él n animales sanos, ¿cómo evaluar los resultados del experimento? Para un suero sin efectividad ninguna la probabilidad de que exactamente k de los n animales inyectados permanezcan sin infección, viene dada por $B(n, 0.75)$. Para $k=n=10$ la probabilidad básica es 0.056 y para $k=n=12$ es 0.032. Así, si entre 10 o 12 animales inyectados ninguno de ellos enferma puede interpretarse este hecho como una prueba de la efectividad del suero utilizado, aunque no se trate de una prueba concluyente. No obstante para $n=17$, la $P(X \leq 1) = 0.0501$, siendo X el número de infectados, ello puede interpretarse en el sentido de que al inyectar 17 animales si solo uno enferma la existencia de la efectividad del suero es mayor que cuando inyectamos a 10 y ninguno enferma. En la misma línea de razonamiento, para $n=23$, $P(X \leq 2) = 0.0492$ y por tanto tendríamos una evidencia más fuerte de la bondad del suero cuando al inyectar a 23 individuos solo 2 de ellos enferman.

LA DISTRIBUCION DE POISSON (Como una aproximación de la binomial)

(1)

En la fabricación de botellas de vidrio, se consideran defectuosas aquellas en las que aparecen partículas sólidas, "piedras", que estaban previamente diluidas en la masa de vidrio fundido. Supongamos que tenemos 100 kgs. de masa, que cada botella requiere 1 kgs para su fabricación y que hay x "piedras" en los 100 kgs. de masa. ¿Cuál será el porcentaje de botellas defectuosas? La respuesta $x/20$ ignora la posibilidad de que en una botella aparezca más de una "piedra". Para contestar a la pregunta podemos recurrir a un modelo probabilístico a base de urnas.

Bajo el supuesto de que cada "piedra" tiene la misma probabilidad de aparecer en cada botella y sta independientemente de lo que ocurre en las otras "piedras", podemos reducir el problema a lo siguiente: se eloran aleatoriamente n bolas en N urnas, ¿cuál es la probabilidad de que una urna elegida al azar contenga exactamente k bolas? Como ya sabemos

$$\begin{aligned} \text{casos posibles } N^n \\ \text{casos favorables } (N-1)^{n-k} \end{aligned}$$

sto para k bolas fijas, pero tengamos en cuenta que stas k bolas pueden elegirse de $\binom{n}{k}$ formas distintas, en consecuencia la probabilidad por cada k

$$W_k = \binom{n}{k} \frac{(N-1)^{n-k}}{N^n} = \binom{n}{k} \frac{1}{N^k} \cdot \left(1 - \frac{1}{N}\right)^{n-k}$$

Si la producción de las N botellas requiere M ^{quintales} de masa de vidrio, tendremos, en ste caso, $N=100M$ y $n=xM$. Como estamos interesados en el porcentaje de botellas defectuosas en un largo periodo de fabricación, suponemos que M es muy grande. Sea $\lambda = \frac{x}{100}$, entonces

$$\begin{aligned} N=100M \\ n=xM \end{aligned} \left\{ \begin{aligned} N &= \frac{100}{x} \cdot n = \frac{n}{\lambda} \end{aligned} \right. \text{, sustituyendo en } W_k \text{, tendremos}$$

$$W_k = \frac{1}{k!} \cdot \prod_{j=0}^{k-1} (n-j) \cdot \left(\frac{1}{n}\right)^k \cdot \left(1 - \frac{1}{n}\right)^{n-k} = \frac{\lambda^k}{k!} \cdot \left(1 - \frac{\lambda}{n}\right)^{n-k} \cdot \prod_{j=0}^{k-1} \left(1 - \frac{j}{n}\right)$$

que M es grande, supone que n es grande y sabemos que

$$\lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n = e^{-\lambda}$$

(2)

$$\text{y que } \lim_{n \rightarrow \infty} \prod_{j=0}^{k-1} \left(1 - \frac{j}{n}\right) = 1$$

entonces

$$\lim_{n \rightarrow \infty} W_k = \frac{\lambda^k}{k!} e^{-\lambda} \quad k=0,1,\dots$$

A la distribución

$$P_k = P(X=k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k=0,1,\dots$$

re la compare con el nombre de distribución de Poisson. Se trata de una probabilidad por urnas

$$\sum_{k=0}^{\infty} P_k = \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} = e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = e^{-\lambda} \cdot e^{\lambda} = 1.$$

Volvamos de nuevo al caso práctico inicial. La relación entre frecuencia relativa y probabilidad hace que la proporción de botellas defectuosas frente al total fabricado sea aproximadamente igual a la probabilidad de que ^{al menos} una botella defectuosa. Esta probabilidad puede aproximarse mediante $1 - W_0 = 1 - e^{-\lambda}$ y como $\lambda = \frac{x}{100}$, el porcentaje de piezas defectuosas será $100(1 - \exp(-\frac{x}{100}))$. Si x es muy pequeño, sta cantidad es prácticamente igual a x , pero para valores grandes x no ocurre así. Por ejemplo, para $x=100$, el porcentaje de botellas defectuosas no es 100 sino $63.21\% = 100(1 - e^{-1})$, cantidad que si es mayor que no ocurre cuando x es tan grande. Si por ejemplo $x=30$, el porcentaje será 25.92% .

OBSERVACION

puede asimilarse a una binomial variando así. La probabilidad de que una bola sea introducida en una urna es $\frac{1}{N}$, y la contraria $(1 - \frac{1}{N})$; por tanto la de obtener k -éxito (éxito = bola en la urna en cuestión) será

$$\binom{n}{k} \left(\frac{1}{N}\right)^k \left(1 - \frac{1}{N}\right)^{n-k}$$

en lugar de 30%, que estudiaríamos resolviendo como al principio. Evidentemente si el número de "piedras" en la mesa es grande y mucho más económico, ni el proceso le permite fabricar botellas pequeñas, ni hay forma posible de limpiar la mesa. Así por ejemplo, fabricando botellas que requieran sólo 0.25 kgs de masa en lugar de 1 kg., el nuevo valor de λ es $\lambda' = \frac{1}{400}$ y la proporción de defectuosas, para $x=30$, baja del 25.92% al 7.23%. La teoría de la probabilidad propiamente, como hemos visto, sugiere interesantes problemas prácticos de producción. (***) VER APENDICE

LA DISTRIBUCIÓN DE POISSON (Como solución a un problema físico-químico)

Supongamos una alta masa de sustancia radiactiva cuyo periodo de vida media es conocido. Supongamos además que las siguientes hipótesis son ciertas:

- 1.- Si $t_1 < t_2 < t_3$ y $A_k(t_1, t_2)$ designa el suceso "durante el intervalo de tiempo (t_1, t_2) ocurren k desintegraciones", entonces los sucesos $A_k(t_1, t_2)$ y $A_l(t_2, t_3)$ son independientes para cualesquiera valores no negativos de k y l .
- 2.- Los sucesos $A_k(t_1, t_2)$, $k=0, 1, \dots$ constituyen una partición del espacio muestral. Para cada k , $P(A_k(t_1, t_2))$ depende sólo de la diferencia $t_2 - t_1$. De otros palabras, el proceso de desintegración radiactiva es homogéneo con respecto al tiempo. $W_k(t)$ designará la probabilidad de k desintegraciones durante un intervalo de tiempo de longitud t ($t_2 - t_1 = t$).
- 3.- Si t es suficientemente pequeña, la probabilidad de que durante un intervalo de tiempo t ocurra más de una desintegración es especialmente pequeña comparada con la probabilidad de que ocurra exactamente una. Es decir

$$\lim_{t \rightarrow 0} \frac{1 - W_0(t) - W_1(t)}{W_1(t)} = 0, \quad (1)$$

o lo que es lo mismo

$$\lim_{t \rightarrow 0} \frac{1 - W_0(t)}{W_1(t)} = 1 \quad (2)$$

De otros palabras: la probabilidad de que ocurra al menos una desintegración es, en el límite, igual a la probabilidad de que ocurra exactamente 1.

Claramente $W_0(0) = 1$ y $W_k(0) = 0$, $k \geq 1$. Además, $W_0(t)$ es una función monótona decreciente. De aquí y de las hipótesis 1 y 2 tenemos

$$W_0(t+s) = P(A_0(t, t_2)) = P(A_0(t, t_2) \cap A_0(t_2, t_3)) = P(A_0(t, t_2)) \cdot P(A_0(t_2, t_3)) = W_0(t) \cdot W_0(s) \quad \text{para } t_2 - t_1 = t \text{ y } t_3 - t_2 = s.$$

al estar por de una función aditiva, si exigimos la derivabilidad de la función, tendemos

$$W_0(t) = e^{-\mu t} \quad \text{con } \mu > 0. \quad (3)$$

De orden a determinar las funciones $W_k(t)$ observemos que

$$\lim_{\Delta t \rightarrow 0} \frac{W_k(\Delta t)}{\Delta t} = 0, \quad k \geq 2 \quad (5)$$

De efecto

$$0 \leq W_k(t) \leq \sum_{k \geq 2} W_k(t) = 1 - W_0(t) - W_1(t), \quad \forall k \geq 2$$

y de aquí

$$0 \leq \frac{W_k(\Delta t)}{\Delta t} \leq \frac{1 - W_0(\Delta t) - W_1(\Delta t)}{\Delta t} \cdot \frac{W_1(\Delta t)}{W_1(\Delta t)} = \frac{1 - W_0(\Delta t) - W_1(\Delta t)}{W_1(\Delta t)} \cdot \frac{W_1(\Delta t)}{\Delta t} \quad (4)$$

de (2), tenemos

$$\lim_{t \rightarrow 0} \frac{(1 - W_0(t))/t}{W_1(t)/t} = 1 \rightarrow \lim_{t \rightarrow 0} \frac{1 - W_0(t)}{t} = \lim_{t \rightarrow 0} \frac{W_1(t)}{t} = W_1'(0)$$

pero el primer miembro de esta última igualdad es $-W_0'(0)$ que existe y por tanto $\lim_{t \rightarrow 0} \frac{W_1(t)}{t}$ es una cantidad finita. Pasando al límite en (4) y teniendo en cuenta (1) llegamos al resultado buscado. Ahora bien, como para $k \geq 1$, $W_k(0) = 0$, (5) puede escribirse

$$W_k'(0) = 0, \quad k \geq 2 \quad (6)$$

lo que prueba la existencia de $W_k'(0)$.

Por otro lado consideremos ahora el suceso "k desintegraciones ocurren durante el intervalo de tiempo $(0, t + \Delta t)$ ". Este suceso puede darse de tres formas distintas:

- a) $k-1$ desintegraciones entre 0 y t y una entre t y $t + \Delta t$,
- b) k desintegraciones entre 0 y t y 0 entre t y $t + \Delta t$,
- c) a lo sumo $k-2$ desintegraciones entre 0 y t y al menos 2 entre t y $t + \Delta t$.

por tanto, de acuerdo con las hipótesis 1 y 2, tendremos

$$W_k(t + \Delta t) = W_{k-1}(t) \cdot W_1(\Delta t) + W_k(t) \cdot W_0(\Delta t) + R \quad (7)$$

donde $R = o(\Delta t)$, de acuerdo con la hipótesis 3 y la relación (5). De aquí

$$W_k(t + \Delta t) - W_k(t) = W_{k-1}(t) [W_1(\Delta t) - 1] + W_k(t) \cdot W_1(\Delta t) + R$$

dividiendo por Δt y pasando al límite

$$\lim_{\Delta t \rightarrow 0} \frac{W_k(t + \Delta t) - W_k(t)}{\Delta t} = W_{k-1}(t) \cdot \lim_{\Delta t \rightarrow 0} \frac{W_1(\Delta t) - 1}{\Delta t} + W_k(t) \cdot \lim_{\Delta t \rightarrow 0} \frac{W_1(\Delta t)}{\Delta t} \quad \text{D por (5)}$$

teniendo en cuenta (3) y el hecho de que $W_0'(0) = -W_1'(0)$, queda

$$W_k'(t) = \mu (W_{k-1}(t) - W_k(t)) \quad , \quad k=1,2,\dots \quad (8)$$

para resolver esta ecuación diferencial hagamos

$$V_k(t) = W_k(t) \cdot e^{\mu t}$$

entonces derivando

$$V_k'(t) = W_k'(t) \cdot e^{\mu t} + W_k(t) \cdot \mu \cdot e^{\mu t}$$

y de aquí

$$W_k'(t) = \frac{V_k'(t)}{e^{\mu t}} - W_k(t) \cdot \mu$$

entonces, de (8)

$$\frac{V_k'(t)}{e^{\mu t}} = \mu \cdot W_{k-1}(t) \rightarrow V_k'(t) = \mu \cdot W_{k-1}(t) \cdot e^{\mu t} = \mu \cdot V_{k-1}(t) \quad , \quad k=1,2,\dots$$

De $W_0(t) = e^{-\mu t}$ se sigue $V_0(t) = 1$ y de aquí

$$V_1(t) = \mu t \quad , \quad V_2(t) = \frac{\mu^2 t^2}{2}$$

en general

$$V_k(t) = \frac{(\mu t)^k}{k!}$$

Por tanto

$$W_k(t) = \frac{(\mu t)^k}{k!} \cdot e^{-\mu t} \quad , \quad k=0,1,\dots$$

Es decir, que el número de desintegraciones durante un intervalo de tiempo t , dada la hipótesis 1-3, tiene una distribución de Poisson con parámetro μt .

OBSERVACION

La distribución de Poisson que acabamos de obtener como solución al problema específico de las desintegraciones de sustancias radiactivas es aplicable, como modelo probabilístico, a un número de situaciones o condiciones de que se unifiquen, debidamente modificadas, las hipótesis 1-3 citadas al comienzo del párrafo. Así por ejemplo, si en lugar de intervalos de longitud t tenemos dominios de área S o volumen V y estamos interesados en calcular la

(5)

probabilidad de encontrar k partículas en un dominio determinado, podemos recurrir al modelo de Poisson a condición de que:

- 1) El proceso estudiado sea homogéneo. Es decir, la probabilidad de encontrar k partículas en un dominio determinado depende sólo del área o volumen del dominio y no de su forma.
- 2) Si el dominio es pequeño (en cuanto a área o volumen), la probabilidad de encontrar más de un punto en dicho dominio es pequeña comparada con el tamaño del evento o incluso si la comparamos con la probabilidad de encontrar una sola partícula.
- 3) Dominios disjuntos son mutuamente independientes.

NOTA HISTÓRICA. OÍDO!!

Siméon D. Poisson vivió de 1781 a 1842. Su distribución de probabilidad la presentó por primera vez en 1837 en un libro titulado "Recherches sur la probabilité de jugement en matière criminelle et en matière civile, précédés des règles générales du calcul des probabilités". Toma un papel!

ALGUNOS EJEMPLOS DE OBSERVACIONES QUE SE AJUSTAN A UNA DISTRIBUCIÓN DE POISSON.

- 1) Desintegraciones radioactivas. Ya hablamos en este caso del ajuste del fenómeno a la distribución de Poisson, pero estudiemos con más detalle un experimento famoso. En 1920, Rutherford, Chadwick y Ellis estudiaron en Cambridge una sustancia radiactiva durante $N=2608$ intervalos de 7.5 segundos cada uno, obteniendo el número de partículas que alcanzaron un contador Geiger. En la tabla se muestran el número N_k de periodos con exactamente k partículas.

k	N_k	$N \cdot P(X=k)$	k	N_k	$N \cdot P(X=k)$
0	57	54.399	5	408	393.515
1	203	210.523	6	273	253.817
2	383	407.361	7	139	140.325
3	525	525.496	8	45	67.882
4	532	508.418	9	27	29.189
			$k \geq 10$	16	17.075
			Total	2608	2608.000

El número total de partículas fue de $T = \sum k N_k = 10094$ y por término medio en cada intervalo $T/N = 3.870$. Se obtuvieron entonces los valores teóricos $N \cdot P(X=k)$, donde $P(X=k)$ se obtiene a partir de una distribución de Poisson con parámetro $\lambda = 3.870$, es decir partículas por unidad de tiempo empleada, a saber intervalos de 7.5 segundos. La comparación de los valores teóricos con los

experimental, con métodos que no hacen al caso ahora, muestran que el experimento en cuestión puede ⁽⁷⁾ explicarse consistentemente mediante la independiente distribución de Poisson.

- II) Bombas volantes sobre Londres. Como ejemplo de una distribución espacial de puntos aleatorios consideremos las actividades de bombas volantes que cayeron sobre Londres durante la Segunda Guerra Mundial. Se divide la ciudad en $N = 576$ áreas pequeñas de superficie $S = \frac{1}{4} \text{ km}^2$ cada una. La tabla presenta el número N_k de áreas con exactamente k bombas. El número total de impactos fue de $T = \sum k \cdot N_k = 837$ y la media de impactos por área $T/N = 0.9323$ que tomaremos

k	0	1	2	3	4	5 y más
N_k	229	211	93	35	7	1
$N \cdot P(X=k)$	226.74	211.39	93.54	30.62	7.14	1.57

como valor de λ para la distribución de Poisson correspondiente. La concordancia entre los datos teóricos y los experimentales es más que aceptable.


Es interesante señalar que existe una creencia general en el sentido de que los impactos tendían a agruparse. Si esto hubiera sido cierto habría existido gran cantidad de áreas con muchos o muy pocos impactos y por contra gran deficiencia de áreas con un número intermedio de impactos. La tabla presentada indica la homogeneidad y aleatoriedad de los áreas y deshace la creencia general que tiende a identificar la aleatoriedad como una cierta tendencia al agrupamiento.

- III) Conexiones telefónicas simultáneas. La tabla presenta estadísticas acerca de las conexiones telefónicas a un número equivocado. El total de $N = 267$ números fueron observados; N_k indica cuántos

k	N_k	$N \cdot P(X=k)$	k	N_k	$N \cdot P(X=k)$
0-2	1	2.05	11	20	24.34
2	5	4.76	12	18	17.72
4	11	10.39	13	12	11.92
5	14	18.16	14	7	7.44
6	22	26.45	15	6	4.33
7	43	33.03	16	2	4.65
8	31	36.09			
9	40	35.04	Total	267	267.00
10	35	30.63			

números tuvieron exactamente k conexiones erróneas. El número medio de las conexiones por número de teléfono equivocado fue de 8.74 que se toma como valor de λ para la distribución de Poisson que nos permite obtener $P(X=k)$.

- IV) Recuentos de hematíes y bacterias.



La figura reproduce una placa de Petri con colonias de bacterias, similares al microscopio como puntos oscuros. La placa se divide en cuadrados pequeños, la tabla reproduce el número de cuadrados observados con exactamente k puntos, en varios experimentos llevados a cabo.

k	0	1	2	3	4	5	6
N_k	5	19	26	26	21	13	8
Poisson	6.1	18.0	26.7	26.4	19.6	11.7	9.5
N_k	8	16	18	15	9	7	
Poisson	6.8	16.2	19.2	15.1	9.0	6.7	
N_k	60	80	45	16	9		
Poisson	62.6	75.8	45.9	18.5	7.3		

El último valor incluye todos aquellos cuadrados con

k o más colonias.

LA DISTRIBUCIÓN BINOMIAL NEGATIVA

Consideremos n pruebas de Bernoulli, es decir, pruebas cuyo resultado es éxito o fracaso con probabilidades p y $q=1-p$, respectivamente. Supongamos además que se trata de pruebas independientes. Estamos interesados en conocer cuando ocurrirá el r -ésimo éxito. Aquí r es un entero positivo fijo. Con las condiciones planteadas, sabemos que la probabilidad de que el r -ésimo éxito ocurra en la prueba $V \leq n$ es independiente de n y depende tan sólo de r , p y q . Puesto que necesariamente $V \geq r$, podemos escribirlo de la forma $V = r+k$. La probabilidad de que el r -ésimo éxito ocurra en la prueba $r+k$ ($k=0, 1, \dots$) la denotaremos mediante $f(k; r, p)$. Esta probabilidad es igual a la probabilidad de que ocurran exactamente k fracasos antes del r -ésimo éxito. Este suceso ocurre si y sólo si entre las $r+k-1$ pruebas hay exactamente k fracasos y en la siguiente, a saber la $(r+k)$ -ésima, el resultado de la prueba es un éxito, la probabilidad de un suceso tal como el anterior viene dada por

$$\binom{r+k-1}{k} p^{r-1} q^k \quad \text{para los } k \text{ fracasos en las } r+k-1 \text{ pruebas, y}$$

p para el último éxito

en consecuencia

$$f(k; r, p) = \binom{r+k-1}{k} p^r q^k, \quad k=0, 1, 2, \dots$$

Que puede también escribirse de la forma

$$f(k; r, p) = \binom{-r}{k} p^r (-q)^k, \quad k=0, 1, 2, \dots$$

de donde se ve el nombre de Binomial negativa. Tengase en cuenta que:

$$\begin{aligned} \binom{-r}{k} &= \frac{(-r)(-r-1)\dots(-r-k+1)}{k!} = \frac{(-r)(-r+1)\dots(-(r+k-1))}{k!} = \frac{(-1)^k r(r+1)\dots(r+k-1)}{k!} \\ &= \frac{(-1)^k (r-1)! r(r+1)\dots(r+k-1)}{(r-1)! k!} = (-1)^k \frac{(r+k-1)!}{(r-1)! k!} = (-1)^k \binom{r+k-1}{k}. \end{aligned}$$

Supongamos ahora que la sucesión de pruebas de Bernoulli la continuamos al término de los necesarios para conseguir los r éxitos. Es claro puede ocurrir que el éxito r -ésimo no aparezca nunca y debemos prolongar nuestra sucesión hasta infinito.

Tenemos así así una variable aleatoria discreta X , que toma los valores $\{0, 1, 2, \dots\}$ y que representa el número de pruebas adicionales a r que debemos realizar para alcanzar

(9)

El éxito si la probabilidad de cada éxito es p , $q=1-p$ la de obtener un fracaso, y las pruebas se llevan a cabo de forma independiente. La probabilidad de que $X=k$, viene dada por

$$P(X=k) = f(k; r, p) = \binom{r+k-1}{k} p^r q^k = \binom{-r}{k} p^r (-q)^k.$$

No debe extrañar nada alguna respecto al hecho de que la función $f(k; r, p)$ es una función de cuantía, por cuanto:

- 1) $f(k; r, p) \geq 0, \forall k$
- 2) $f(k; r, p)$ es distinta por cuanto toma valores distintos de cero para $k=0, 1, 2, \dots$ que es un conjunto denso de enteros
- 3) $f(k; r, p)$ es normalizada. En efecto

$$\sum_{k=0}^{\infty} f(k; r, p) = 1$$

ya que si recordamos el desarrollo en serie de MacLaurin de la función $(1-x)^{-r}$ tenemos:

$$\frac{1}{(1-x)^r} = \sum_{j=0}^{\infty} \binom{r+j-1}{j} x^j, \quad |x| < 1$$

en nuestro caso

$$\sum_{k=0}^{\infty} \binom{r+k-1}{k} p^r q^k = p^r \sum_{k=0}^{\infty} \binom{r+k-1}{k} q^k = p^r \cdot \frac{1}{(1-q)^r} = 1, \quad |q| < 1.$$

La distribución de probabilidad Binomial negativa es conocida también como distribución de Pascal. Para $r=1$ la distribución se conoce con el nombre de distribución geométrica y su función de cuantía se reduce a $f(k; 1, p) = p \cdot q^k, k=0, 1, 2, \dots$.

EJEMPLOS

I) El problema de las cajas de cerillas de Borel. Un conocido matemático lleva consigo una caja de cerillas en cada uno de los dos bolsillos de su chaqueta. Cuando necesita una cerilla selecciona al azar uno de los bolsillos de manera que las sucesivas elecciones constituyen pruebas de Bernoulli con $p=\frac{1}{2}$. Supongamos que inicialmente cada caja contiene exactamente N cerillas y consideremos el momento en el cual, por primera vez, el matemático descubre que

Una de las cajas está vacía. En este momento la otra caja puede contener $0, 1, 2, \dots, N$ cuillitas, (11) y vamos a designar mediante u_r la correspondiente probabilidad. Identificaremos al "éxito" con la decisión del bolsillo "trapiendo". Este bolsillo estará vacío, o mejor, describiremos que está vacío justo en el momento que el bolsillo derecho contiene exactamente r cuillitas, si y sólo si exactamente $(N-r)$ fracasos han precedido al $(N+1)$ -ésimo éxito. La probabilidad de este suceso es $f(N-r; N+1, \frac{1}{2})$. El mismo argumento puede aplicarse respecto al bolsillo derecho y por tanto la probabilidad buscada es

$$u_r = 2f(N-r; N+1, \frac{1}{2}) = 2 \cdot \binom{2N-r}{N-r} \left(\frac{1}{2}\right)^{N+1} \cdot \left(\frac{1}{2}\right)^{N-r} = \binom{2N-r}{N} 2^{-2N+r}.$$

Por ejemplo, para $N=50$ y $r=4$, $u_r = 0.074790$ y para $r=29$, $u_r = 0.000232$.

II) Generalización: Tenis de mesa. La naturaleza del problema anterior queda más de manifiesto cuando se atribuyen diferentes probabilidades a cada una de las cajas. Interpretaremos esto de forma diferente. Supongamos que dos amigos, Pedro y Pablo, juegan a un juego que puede ser tratado como una sucesión de pruebas de Bernoulli en las que las probabilidades p y q varían como medida de la destreza de los jugadores. En el tenis de mesa el jugador que primero llega a 21 gana la partida. Por comparación con el ejemplo precedente consideremos la situación general en la que $2v+1$ éxitos individuales se requieren. El juego finaliza, en el mejor de los casos en la prueba $2v+1$ (caso de 21 a 0) o bien, en la peor de las situaciones, en la prueba $4v+1$ (20 a 21). Designemos por a_r la probabilidad de que Pedro gane en la prueba (jugada) $4v+1-r$. Esto ocurrirá si y sólo si, en las $4v-r$ primeras jugadas Pedro ha obtenido $2v$ tantos (éxitos) y además gana la jugada siguiente. Así pues

$$a_r = f(2v-r; 2v+1, p) = \binom{4v-r}{2v} p^{2v+1} q^{2v-r}. \quad (1)$$

La probabilidad de que Pedro gane viene dada por $a_0 + a_1 + \dots + a_{2v}$, la probabilidad de que el juego termine (gana uno u otro) en la jugada $4v+1-r$ viene dada por $a_r + b_r$, donde b_r , probabilidad de que gane Pablo en la jugada $4v+1-r$, viene dada por (1) con p y q intercambiados.

Para $2v=N$, $p=q=\frac{1}{2}$, las probabilidades $a_r + b_r$ se reducen a las u_r del ejemplo anterior.

Nota - El ejemplo de las cuillitas de Banach se debe a Banach en tanto de lo que puede parecer. Tiene su origen en una referencia humorística al hábito de fumar del Banach hecho por H. Steinhaus en un acto celebrado en honor de Banach. La anécdota se hizo famosa y de aquí que haya conserido el nombre hasta ahora.

LA DISTRIBUCIÓN HIPERGEOMÉTRICA

Supongamos n bolas de una urna de las cuales n_1 son rojas y $n_2 = n - n_1$ son negras. Se extraen r al azar. Buscamos la probabilidad de que en las r bolas extraídas haya exactamente k rojas y designemos por q_k dicha probabilidad. k es cualquier valor entre 0 y n_1 , o r si este es más pequeño.

Para encontrar q_k , observemos que el grupo de r bolas contiene k bolas rojas y $r-k$ negras. Las rojas pueden elegirse de $\binom{n_1}{k}$ formas diferentes, mientras que las negras pueden ser de $\binom{n-n_1}{r-k}$ formas distintas. Puesto que la elección de las k rojas puede combinarse con cualquiera de las posibles elecciones de las $r-k$ negras, tendremos

$$q_k = \frac{\binom{n_1}{k} \binom{n-n_1}{r-k}}{\binom{n}{r}}$$

Si en las condiciones enunciadas, definimos una variable X cuyos valores representan el número de bolas rojas en la muestra extraída, esta variable es una variable aleatoria discreta cuyos probabilidades, $P(X=k)$ vienen dadas por

$$P(X=k) = q_k = \frac{\binom{n_1}{k} \binom{n-n_1}{r-k}}{\binom{n}{r}} \quad \begin{array}{ll} k=0, 1, \dots, r & \text{si } r \leq n_1 \\ k=0, 1, \dots, n_1 & \text{si } n_1 < r \leq n. \end{array}$$

Obsérvese que

$$\sum_{k=0}^r P(X=k) = \sum_{k=0}^r q_k = \frac{1}{\binom{n}{r}} \sum_{k=0}^r \binom{n_1}{k} \binom{n-n_1}{r-k} = \frac{1}{\binom{n}{r}} \cdot \binom{n}{r} = 1.$$

EJEMPLOS.

I) El Senado de los EE.UU. está compuesto por 100 senadores, 2 por cada uno de los 50 estados. Se elige un grupo de 50 senadores y se quiere conocer la probabilidad de que un estado determinado no esté representado en el grupo y la de que en el grupo haya 1 senador de este estado o los 2 senadores del mismo estado.

Aquí asimilaremos senadores del estado en cuestión a "rojos", con lo que $n_1=2$, $r=50$ y $n=100$ por tanto

$$q_0 = q_2 = \frac{50 \cdot 49}{100 \cdot 99} = 0.24747 \dots \quad y \quad q_1 = \frac{50}{99} = 0.50505 \dots$$

II) Estimación del tamaño de una población animal a partir de datos de captura. Supongamos que 1000 peces capturados en un lago son marcados mediante una mancha roja y se los suelta nuevamente al lago. Después de cierto tiempo se lleva a cabo una nueva captura de otros 1000 peces y 100 de entre ellos llevan la mancha roja. ¿Qué conclusiones podemos extraer respecto al número de peces en el lago? Este es un problema típico de estimación estadística. No es momento de profundizar y describir los distintos métodos que podrían utilizarse para su resolución, nos limitaremos a demostrar cómo la distribución hipergeométrica nos proporciona una clave para la solución de nuestro problema. Suponemos naturalmente que las dos capturas pueden ser consideradas como muestras aleatorias de la población total de peces del lago. (Esta práctica semejante suposición excluye situaciones en las que las dos capturas se hacen en una misma brevedad y en un corto periodo de tiempo). Suponemos también que el número de peces en el lago no cambia entre las dos capturas.

Generalizemos el problema admitiendo tamaños arbitrarios de las muestras. Sean

n = el número total de peces en el lago (desconocido)

n_1 = número de peces en la primera captura. Harán el papel de bolitas rojas.

r = número de peces en la segunda captura.

k = número de peces con mancha roja en la segunda captura.

$q_k(n)$ = probabilidad de que la segunda captura contenga exactamente k peces con mancha roja.

Con esta formulación es obvio que $q_k(n)$ viene dada por la correspondiente probabilidad hipergeométrica, a saber

$$q_k(n) = \frac{\binom{n_1}{k} \binom{n-n_1}{r-k}}{\binom{n}{r}}.$$

En la práctica n_1, r y k pueden conocerse por observación, pero n es desconocido. Así se que imaginaremos n como un número fijo desconocido cuyo valor en modo alguno depende del azar. Suponemos que $n_1 + r - k$ peces han sido capturados en el lago entre las dos capturas, llevados a cabo y que obviamente $n \geq n_1 + r - k$. Es lo más que podemos asegurar con certeza. De nuestro ejemplo $n_1 = r = 1000$ y $k = 100$; es obviamente posible que $n = 1900$, pero si comenzamos con una hipótesis de este tipo, lleguemos a la conclusión de que ha ocurrido un suceso con una probabilidad extraordinariamente pequeña. En efecto, suponiendo que $n = 1900$, la probabilidad $q_k(n)$ vendrá dada, con los datos concretos del problema, por

$$q_k(1900) = \frac{\binom{1000}{100} \binom{900}{900}}{\binom{1900}{1000}} = \frac{(1000!)^2}{100! \cdot 1900!}$$

utilizando la fórmula de Stirling, $n! \sim \sqrt{2\pi n} \cdot n^{n+\frac{1}{2}} \cdot e^{-n}$, para aproximar los factoriales lleguemos a que $q_k(1900) \sim 10^{-430}$ y en una situación así el resultado común nos lleva a rechazar la hipótesis como consistente de todo sentido. Un razonamiento similar nos induciría a rechazar hipótesis del tipo, n es muy grande, por ejemplo $n = 10^6$. Esta consideración nos induce a buscar un valor de n para el cual $q_k(n)$ alcance su mayor valor, puesto que en este caso nuestra observación tendría la mayor probabilidad de producirse. Para cualquier conjunto particular de observaciones n_1, r, k , el valor de n para el que $q_k(n)$ es más grande se designa mediante $\hat{n}$ y se le llama estimación máximo verosímil de n . Conviene a continuación considerar el criterio

$$\frac{q_k(n)}{q_k(n-1)} = \frac{(n-n_1)(n-r)}{(n-n_1-r+k)n} = \frac{n^2 - n_1n - nr + n_1r}{n^2 - n_1n - nr + nk}$$

Este criterio es mayor o menor que la unidad según que $nk < n_1r$ o $nk > n_1r$. Esto significa que a medida que n aumenta la relación $q_k(n)$ hace primero para crecer después alcanzando su máximo cuando n sea igual al mayor entero menor que n_1r/k . En nuestro caso particular $\hat{n} = 10000$.

El verdadero valor de n puede ser mayor o menor que el encontrado, y estamos interesados también en dar unos límites dentro de los cuales sea razonable encontrar el verdadero valor de n . Supongamos para ello que n es más pequeño que 8500. Sustituimos en la correspondiente expresión de $q_k(n)$ y calculamos la probabilidad de que la segunda captura contenga a lo sumo 100 peces marcados. Esta probabilidad viene dada por

$$x = q_0 + q_1 + \dots + q_{100}$$

y es igual a 0.04. Análogamente para $n = 12000$, la probabilidad de que la segunda captura contenga al menos 100 peces marcados es alrededor de 0.03. Con semejantes probabilidades es razonable pensar que el verdadero valor de n está alguno de los comprendidos entre 8500 y 12000.

APENDICE

A-①

Cont. de la DISTRIBUCION DE POISSON Como aproximación a la Binomial

Antes vimos una situación muy concreta, a saber, la fabricación de botellas de vidrio y la determinación aproximada del número de botellas defectuosas. Ahora bien, ¿cómo podemos utilizar esta aproximación ante una situación genérica definida mediante una binomial cualquiera $B(n, p)$? La forma de actuar quedará explicada en cuanto pongamos de manifiesto la relación existente entre los parámetros n, p y λ de la Binomial y la aproximación de Poisson, respectivamente. Volvamos al ejemplo, recordemos que $\lambda = \frac{x}{100}$ y que por otra parte $N = \frac{n}{\lambda}$, o bien

$$\lambda = \frac{n}{N} = n \cdot \left(\frac{1}{N}\right)$$

De esta Binomial $p = \frac{1}{N}$ y por tanto $\lambda = n \cdot p$, este resultado no se da por casualidad, sino que está en la relación que existe, en general, entre el parámetro λ y los parámetros n, p de la Binomial. Distiguemos además el hecho de que n es grande y $p = \frac{1}{N}$ es pequeño, por cuanto que habíamos señalado que la aproximación era tanto mejor cuanto mayor fuera el número de botellas fabricadas, N .

Podríamos, de hecho, haber planteado el problema de forma genérica, a continuación lo haremos, pero poco a poco más abstracto haciendo mediante un caso práctico.

Sea ahora $B(n, p)$ una Binomial tal que n es muy grande y p es muy pequeño, de manera que pueden plantearse dificultades a la hora de determinar las probabilidades $P(X=k)$, $k=0, 1, \dots, n$. Hagamos $\lambda = n \cdot p$. Sabemos que

$$\left. \begin{aligned} P(X=0) &= (1-p)^n = \left(1 - \frac{\lambda}{n}\right)^n \\ \text{para } n \text{ grande} \quad \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n &= e^{-\lambda} \end{aligned} \right\} P(X=0) \approx e^{-\lambda} \quad (1)$$

Por otra parte

$$\frac{P(X=k)}{P(X=k-1)} = \frac{(n-k+1)p}{kq} = \frac{\lambda - (k-1)p}{kq}$$

que para p pequeño (entonces q estará muy próximo a la unidad), puede aproximarse mediante

$$\frac{P(X=k)}{P(X=k-1)} \approx \frac{\lambda}{k} \quad (2)$$

de (1) y (2), tenemos

$$P(X=1) \approx \lambda \cdot P(X=0) \approx \lambda \cdot e^{-\lambda}$$

$$P(X=2) \approx \frac{\lambda}{2} \cdot P(X=1) \approx \frac{\lambda^2}{2} \cdot e^{-\lambda}$$

$$P(X=3) \approx \frac{\lambda}{3} \cdot P(X=2) \approx \frac{\lambda^3}{2 \cdot 3} \cdot e^{-\lambda}$$

$$P(X=k) \approx \frac{\lambda}{k} \cdot P(X=k-1) \approx \frac{\lambda^k}{k!} e^{-\lambda}$$

Es decir, las probabilidades binomiales $B(n, p)$ pueden aproximarse mediante las probabilidades de una distribución de Poisson, $P(\lambda)$, con $\lambda = n \cdot p$, siendo la aproximación tanto mejor cuanto mayor sea n y menor p .

$$P(X=k) = \binom{n}{k} p^k (1-p)^{n-k} \approx \frac{\lambda^k}{k!} e^{-\lambda} \quad \lambda = n \cdot p$$

EJEMPLOS de aproximación

I) Cumpleaños. ¿Cuál es la probabilidad, p_k , de que en una compañía de 500 artistas exactamente k celebren su cumpleaños el día de Año Nuevo? En el supuesto de la elección aleatoria de los 500 artistas, la probabilidad podrá obtenerse a partir de una Binomial $B(500, \frac{1}{365})$, o bien aproximarla mediante una Poisson, $P(\lambda)$, con $\lambda = \frac{500}{365} = 1.3699\dots$. A continuación se presentan las probabilidades exactas y sus aproximaciones.

k	0	1	2	3	4	5	6
Binomial	0.2537	0.3484	0.2388	0.1089	0.0372	0.0101	0.0023
Poisson	0.2541	0.3481	0.2385	0.1089	0.0373	0.0102	0.0023

II) Piezas defectuosas. Una máquina fabrica tornillos y produce un medio 15 de cada mil con defectos. Estamos interesados en saber, ¿cuántos tornillos deben ponerse en una caja para que la probabilidad de encontrar al menos 100 tornillos correctos sea mayor o igual que 0.8?

En el supuesto de ponerlos en caja de 100 unidades la probabilidad de no encontrar tornillos defectuosos en una caja puede evaluarse a partir de una Binomial $B(100, 0.015)$, de manera que

$$P(X=0) = (0.985)^{100} = 0.22061$$

o bien mediante una aproximación de Poisson, $P(1.5)$, $P(X=0) = e^{-1.5} = 0.22313\dots$

aproximación que damos por buena a efectos prácticos.

A-3

A la vista de las probabilidades obtenidas parece claro que las cajas debían contener más de 100 bombillos, ~~si se $x=1$ o $x=2$ se obtiene una probabilidad de 0.56 y 0.809 respectivamente~~. Supongamos pues que la caja contiene $100+x$ bombillos, con x entero y pequeño. Aplicamos la aproximación de Poisson con $\lambda = n \cdot p = (100+x) \cdot 0.015 \approx 1.5$. La probabilidad de que haya al menos 100 bombillos buenos es la misma de encontrar a lo sumo x bombillos defectuosos, por tanto

$$P(X \leq x) = \sum_{k=0}^x \frac{\lambda^k}{k!} \cdot e^{-\lambda} = e^{-1.5} \left[1 + \frac{1.5}{1} + \dots + \frac{(1.5)^x}{x!} \right] \geq 0.8$$

Existen tablas adecuadas para determinar el valor aproximativo a partir del valor de x , encontramos en ellas que para $x=1$, $P(X \leq 1) \approx 0.56$ y para $x=2$, $P(X \leq 2) = 0.809$.
Habría pues que cambiar los bombillos en cajas de 102 unidades.

El verdadero valor de $P(X \leq 2)$ obtenido a partir de una Binomial $B(102, 0.015)$ es 0.8022 - muy próxima al resultado con nuestra aproximación.

III) Un ejemplo empírico. El número de veces que aparece el par (7,7) entre 100 pares de números aleatorios, este se sigue una distribución binomial $B(100, 0.01)$. En la tabla se muestran las frecuencias absolutas, N_k , de k apariciones del par (7,7) en 100 grupos de 100 pares de dígitos aleatorios. Se presentan también en la tabla los valores teóricos de la distribución binomial y de la correspondiente aproximación de Poisson, $P(\lambda)$, con $\lambda = n \cdot p = 1$. Las frecuencias relativas observadas, $N_k/100$, están razonablemente de acuerdo con las probabilidades teóricas de ambas distribuciones dadas.

k	P(X=k)		N _k
	B(100, 0.01)	P(1)	
0	0.366032	0.367879	41
1	0.369730	0.367879	34
2	0.184865	0.183940	16
3	0.060999	0.061313	8
4	0.014942	0.015328	0
5	0.002898	0.002066	1
6	0.000463	0.000511	0
7	0.000063	0.000073	0
8	0.000007	0.000009	0
9	0.000001	0.000001	0

A-4

Capítulo 5

Variables aleatorias continuas

VARIABLES ALEATORIAS CONTINUAS

I. UNA CARACTERIZACIÓN DE LAS FUNCIONES MEDIBLES

Recordemos que una función medible es una aplicación entre un espacio Ω , dotado de una σ -álgebra de sus partes, $\mathcal{B}$, y la recta real $\mathbb{R}$, provista de la correspondiente tribu de Borel, que verificaba

$$f^{-1}(B) \in \mathcal{B}, \quad \forall B \in \beta, \text{ donde } \beta \text{ es la tribu } (\sigma\text{-álgebra}) \text{ de borel.}$$

Por otra parte, una función simple es aquella que siendo medible tenía un rango finito, lo que equivale a decir que una función simple es de la forma

$$s = \sum_{i=1}^n a_i \cdot \varphi_{A_i} \quad a_i \in \mathbb{R}, \quad i=1, \dots, n$$

donde $\{A_i\}_{i=1}^n$ es una partición medible finita del espacio Ω , es decir, $\Omega = \bigcup_{i=1}^n A_i$, $A_i \cap A_j = \emptyset$ si $i \neq j$, $A_i \in \mathcal{B}$, $\forall i$.

Existe una caracterización de las funciones medibles mediante funciones simples que damos a continuación en forma de teorema, cuya demostración omitiremos.

TEOREMA - Una aplicación f del espacio medible $(\Omega, \mathcal{B})$ en el espacio medible $(\mathbb{R}, \beta)$, que sea no negativa, es medible $\Leftrightarrow \exists$ una sucesión monótona de funciones simples que converja a f (las funciones simples son también no negativas).

Si pretendemos trabajar con una función medible cualquiera, no necesariamente no negativa, podemos dar una caracterización semejante, descomponiéndola en la suma de la función de funciones simples, basada en el hecho de que toda función admite una descomposición del tipo

$$f = f^+ - f^-$$

donde

$$f^+ = \begin{cases} f & \text{si } f \geq 0 \\ 0 & \text{si } f < 0 \end{cases} \quad y \quad f^- = \begin{cases} |f| & \text{si } f \leq 0 \\ 0 & \text{si } f > 0 \end{cases}$$

y por tanto f^+ y f^- son no negativas. El teorema correspondiente dice

TEOREMA - Una aplicación f de $(\Omega, \mathcal{B})$ en $(\mathbb{R}, \beta)$ es medible $\Leftrightarrow \exists$ una sucesión de funciones simples que converja a f .

II. CONTINUIDAD ABSOLUTA

II.a) Medida absolutamente continua. Sea $(\Omega, \mathcal{B})$ un espacio medible y consideremos dos medidas, μ y λ .

Definición I: Decimos que μ es absolutamente continua respecto a λ si $\mu(A) = 0$ para cada conjunto A de $\mathcal{B}$ tal que $\lambda(A) = 0$.

Si la medida μ es finita la definición dada es equivalente a,

Definición II: μ es absolutamente continua respecto a λ si para cada $\varepsilon > 0$, $\exists \delta > 0$ tal que $\mu(E) < \varepsilon$ siempre que $\lambda(E) < \delta$, con $E \in \mathcal{B}$.

II.b) Función absolutamente continua. Existe un concepto designado de la misma manera que hace referencia a las funciones a valores reales. Luego veremos que esta igualdad de nombres no es casual.

Definición III: Una función f a valores en $\mathbb{R}$ se dice que es absolutamente continua si, dado $\varepsilon > 0$, $\exists \delta > 0 / \forall \{I_i\}_{i=1}^n$ intervalos disjuntos verificando

$$\sum_{i=1}^n (b_i - a_i) < \delta \quad \text{entonces} \quad \sum_{i=1}^n |f(b_i) - f(a_i)| < \varepsilon.$$

Como consecuencia de esta definición es muy fácil comprobar que una función absolutamente continua y uniformemente continua.

II.c) Relación entre ambos conceptos. Un caso especialmente interesante es aquel en que las medidas utilizadas son unas determinadas, y además, también lo es el espacio medible utilizado. Situación que permite además, poner de manifiesto el porque ambos conceptos se designan de la misma forma.

Saperejauris que $(\mathbb{Q}, \mathcal{B}) \equiv (\mathbb{R}, \beta)$ y además μ es una medida de probabilidad sobre $(\mathbb{R}, \beta)$ cuando λ la medida de Lebesgue sobre los reales, es decir, aquella que sobre cada intervalo vale la longitud del mismo.

Queremos que a partir de P , medida de probabilidad, podamos definir una función, que resulte ser de distribución dada, mediante la relación $F(x) = P(I_{(-\infty, x]})$. Observamos que si P es absolutamente continua respecto a λ , tendríamos que

dado $\varepsilon > 0$, existiríamos $I = \bigcup_{i=1}^n [a_i, b_i]$ con $\sum_{i=1}^n (b_i - a_i) < \delta$ tal que $P(I) < \varepsilon$, de manera que si

$$\lambda(I) = \sum_{i=1}^n \lambda([a_i, b_i]) = \sum_{i=1}^n (b_i - a_i) < \delta$$

alando δ de modo en función del ε , tendríamos $P(I) < \varepsilon$, pero

$$P(I) = \sum_{i=1}^n P([a_i, b_i]) = \sum_{i=1}^n [F(b_i) - F(a_i)] < \varepsilon$$

lo que quiere decir que F es una función absolutamente continua. Hemos visto por que P absolutamente continua $\Rightarrow F$ absolutamente continua. Puede compararse lo que aquí el momento, que la implicación anterior también es cierta, lo que nos permite establecer la siguiente importante relación:

TEOREMA - Sea F una función de distribución de probabilidad. F es absolutamente continua si y sólo si la correspondiente medida de probabilidad, P , que da origen a F es absolutamente continua respecto a λ , medida de Lebesgue.

III. INTEGRACION RESPECTO DE UNA MEDIDA

Consideramos el espacio de medida $(\Omega, \mathcal{A}, \mu)$ y una función simple s , definida sobre Ω .
Definición: La integral $\int_A s$ respecto de la medida μ , se designa mediante el símbolo $\int_A s d\mu$ y se define mediante la relación:

$$\int_A s d\mu = \sum_{i=1}^n a_i \cdot \mu(A \cap A_i), \text{ donde } A \in \mathcal{A}.$$

Esta relación está siempre bien definida por cuanto $a_i \cdot \mu(A \cap A_i)$ no tiene igual a 0, cuando $a_i = 0$ y $\mu(A \cap A_i) = +\infty$.

La definición puede extenderse de inmediato a cualquier función medible no negativa que tengamos sobre Ω , de la siguiente forma.

Definición: La integral sobre A de f respecto de la medida μ se define

$$\int_A f d\mu = \sup \left\{ \int_A s d\mu ; 0 \leq s \leq f \right\}.$$

El conjunto sobre el cual tenemos el supremo, es no vacío de acuerdo con la caracterización dada para las funciones medibles no negativas, lo que garantiza la existencia de la definición.
Propiedades de la integral. La aplicación así definida, en definitiva no es más que una aplicación de $\mathcal{A}$ en $\mathbb{R}_+$ que posee una serie de propiedades que no vamos a demostrar pero que si enumeramos en algún caso concreto:

a) Si $a \geq 0$, $\int_A a f d\mu = a \int_A f d\mu$.

b) Si $A_1 \subset A_2$, $\int_{A_1} f d\mu \leq \int_{A_2} f d\mu$.

c) Si $f \leq g$, $\int_A f d\mu \leq \int_A g d\mu$.

d) La aplicación λ definida de $\mathcal{A}$ en $\mathbb{R}_+$ mediante $\lambda(A) = \int_A f d\mu$, $A \in \mathcal{A}$ y f

una función medible no negativa dada, es una medida.

e) Para f, g medibles y no negativos, tenemos $\int_A (f+g) d\mu = \int_A f d\mu + \int_A g d\mu$.

a) + e) Implica que para f, g medibles y no negativos $\int_A (af+bg) d\mu = a \int_A f d\mu + b \int_A g d\mu$ viendo los coeficientes de la combinación lineal no negativos.

f) Si A es tal que $\mu(A) = 0$, entonces $\int_A f d\mu = 0$, f medible y no negativa.

g) Si A es tal que $\mu(A) > 0$ y f medible y no negativa es tal que $\int_A f d\mu = 0$ entonces $f = 0$ c.p.p. (con probabilidad 1, es decir salvo en un conjunto que tiene medida nula).

Integración de funciones medibles cualquiera. Hemos introducido el concepto de integral únicamente para el caso de funciones medibles no negativas, el último paso consiste en generalizar el concepto para funciones medibles cualquiera, y simultáneamente introducir el concepto de integrabilidad.

Definición: Sea f una función medible cualquiera sobre el espacio de medida $(\Omega, \mathcal{A}, \mu)$, decimos que f es integrable sobre $A \in \mathcal{A}$, si $\int_A f^+ d\mu$ y $\int_A f^- d\mu$ son finitos. En este caso definimos la integral de f mediante

$$\int_A f d\mu = \int_A f^+ d\mu - \int_A f^- d\mu.$$

La integral así definida goza prácticamente de las mismas propiedades antes citadas, por ejemplo es un operador lineal, es decir

$$\int_A (af+bg) d\mu = a \int_A f d\mu + b \int_A g d\mu, \quad f, b \in \mathbb{R} \quad f, g \text{ medibles.}$$

si bien algunas de ellas, se pierden, por ejemplo $\lambda(A) = \int_A f d\mu$ no es una medida, ya que no puede garantizarse que sea siempre una cantidad no negativa. Surgen, sin embargo, propiedades nuevas, una por ejemplo muy conocida:

$$\left| \int_A f d\mu \right| \leq \int_A |f| d\mu.$$

Observación: El concepto de integrabilidad es aplicable a cualquier función medible y por tanto también a las no negativas. En este concepto equivale a decir que el valor de su integral, que siempre está definida, es finito.

IV. UNA IMPORTANTE PROPIEDAD DE LAS MEDIDAS ABSOLUTAMENTE CONTINUAS

Volvamos nuevamente a las condiciones iniciales del apartado II.a) y supongamos además que las dos medidas, λ y μ , son σ -finitas. Existe un importantísimo teorema que relaciona una medida absolutamente continua respecto a otra con la existencia de una integral.

TEOREMA DE RADON-NIKODYM. Sea μ una medida absolutamente continua respecto a λ y sea, a su vez, ambas σ -finitas. Existe entonces una función medible f , no negativa, de manera que para cualquier conjunto medible $A \in \mathcal{A}$ tenemos

$$\mu(A) = \int_A f d\lambda.$$

A f se la conoce con el nombre de derivada de Radon-Nikodym de μ respecto de λ , y se la designa a veces mediante $\left[\frac{d\mu}{d\lambda} \right]$.

El teorema de Radon-Nikodym para medidas de probabilidad. El teorema adquiere especial relevancia para nosotros cuando μ es una medida de probabilidad, P , y λ es la medida de Lebesgue. Sabemos que tanto una como otra son medidas σ -finitas con lo que el teorema tiene total validez en semejante situación. Tendremos pues, que $\exists f$, medible, finita, no negativa, de manera que

$$P(A) = \int_A f d\lambda, \text{ con } A \in \beta$$

cundo $\int_A f d\lambda$ una integral de Lebesgue con llamada por ser λ la medida de Lebesgue. Obtenemos que para $A =]a, b]$, tenemos

$$P([a, b]) = \int_{A=(a, b]} f d\lambda$$

pero si F es la función de distribución de probabilidad definida a partir de P , la anterior igualdad puede escribirse

$$F(b) - F(a) = \int_{[a, b]} f d\lambda$$

en particular para $a = -\infty$, llegamos a

$$F(b) = \int_{]-\infty, b]} f d\lambda \quad \forall b \in \mathbb{R}$$

que preferimos escribir de la forma

$$F(x) = \int_{]-\infty, x]} f d\lambda \quad \forall x \in \mathbb{R}.$$

Por otra parte $F(x)$ por ser F no decreciente tiene derivada casi por todos los puntos y además, es finita casi por todos los puntos, una importante propiedad que no demostramos, nos permite afirmar que $F' = f$ c.p.p. y la última igualdad puede también escribirse

$$F(x) = \int_{]-\infty, x]} F' d\lambda \quad \forall x \in \mathbb{R}$$

porque además de ser finita c.p.p., F' es medible e integrable y no negativa c.p.p. por serlo F .

V. DEFINICIÓN DE VARIABLE ALEATORIA CONTINUA

Sea X una v.a. definida en $(\Omega, \mathcal{B}, P)$ en $(\mathbb{R}, \beta, P')$, decimos que X es ~~una~~ una v.a. del tipo continuo, o simplemente una v.a. continua si la medida de probabilidad P' es absolutamente continua respecto de la medida de Lebesgue, lo que equivale a decir que F , función de distribución de probabilidad definida a partir de P' , es absolutamente continua.

Como consecuencia de esta definición existirá una función f , medible, finita y no negativa tal que

$$F(x) = \int_{-\infty}^x f d\lambda \quad \text{o también} \quad P'(A) = \int_A f d\lambda, \quad \forall x \in \mathbb{R}, \forall A \in \beta,$$

a la función f se la conoce con el nombre de función de densidad de probabilidad de la variable aleatoria X . Esta función tiene además una propiedad importante, a saber

$$\int_{-\infty}^{+\infty} f d\lambda = 1$$

puesto

$$\int_{-\infty}^{+\infty} f d\lambda = F(+\infty) = \lim_{x \rightarrow +\infty} F(x) = 1.$$

Caracterización de una distribución de probabilidad mediante la función de densidad de probabilidad

Recordemos que en el caso de variables aleatorias discretas podemos caracterizar la distribución de probabilidad, es decir, la medida de probabilidad inducida o la función de distribución correspondiente con sólo conocer la función de cuantía. Exactamente el mismo procedimiento puede ser utilizado en nuestra situación actual, así como la función de distribución (o la medida de probabilidad) de una v.a. continua nos define una función, la de densidad de probabilidad, a partir de una función con características similares a ésta podemos volver el camino inverso para llegar al anterior punto de partida. Ello quiere decir que una v.a. continua, una, concretamente, una distribución de probabilidad puede ser caracterizada mediante la correspondiente función de densidad. Veámoslo.

Teorema.- Sea f una función integrable Lebesgue, es decir, medible y con $\int_{\mathbb{R}} f d\lambda < +\infty$ tal que

- $f \geq 0$ finita
- f es no negativa
- $\int_{-\infty}^{+\infty} f d\lambda = 1$

entonces f es la función de densidad de probabilidad de alguna variable aleatoria del tipo continuo, X .

Demostración.- Basta comprobar que la función $F(x)$ definida mediante

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

Si una función de distribución de probabilidad, por tanto, $F(+\infty) = \int_{-\infty}^{+\infty} f(t) dt = 1$.
 a partir de F podemos definir una medida de probabilidad, P →
 sobre los Borelianos de $\mathbb{R}$ que puede construirse mediante una variable aleatoria
 definida en $(R, \mathcal{B}) \xrightarrow{\text{ca}} (R, \mathcal{B})$, concretamente la identidad.

De usamen, cuando hay que caracterizar una v.a. continua lo hacemos indistintamente con
 P , F , función de distribución (f.d.) o f , función de densidad de probabilidad (f.d.p.).

Propiedad.- Recordemos que en cualquier caso la variable aleatoria X , P la medida de probabilidad inducida

$$P(\{a\}) = P(X=a) = F(a) - F(a-0)$$

Si X es del tipo discreto y $a \in \mathbb{R}$ sabemos que $F(a) \neq F(a-0)$ y $P(X=a) = P(\{a\}) \neq 0$.

Una variable aleatoria continua se caracteriza por poseer una f.d., F , que es absolutamente
 continua y por tanto continua, esto quiere decir que $F(x) = F(x-0)$, $\forall x \in \mathbb{R}$ y de
 aquí

$$P(\{a\}) = P(X=a) = 0, \forall a \in \mathbb{R}. \text{ Si } X \text{ es una v.a. continua.}$$

Relación entre la integral de Lebesgue y la integral de Riemann. Antes de continuar vamos a una inte-
 rante relación entre ambas integrales que nos será útil para estudiar las v.a. continuas.

Se puede demostrar, teorema de Vitali, que toda función integrable Riemann es integrable Lebesgue
 y además, en integrales son iguales. El recíproco no es cierto.

La importancia de este hecho radica en que normalmente las variables aleatorias continuas que
 utilizaremos dan lugar a f.d.p., f , que son continuas y por tanto integrables Riemann (una
 función es integrable Riemann si y solo si los puntos de discontinuidad de la función forman un
 conjunto de medida de Lebesgue nula). Esto implica que todas las integrales que aparezcan en
 la definición de v.a. continua pueden ser consideradas como integrales de Riemann, con
 la excepción que ello comporta. [A señalar que las f.d.p.'s que utilizaremos serán tales que
 las integrales impropias de Riemann utilizadas son convergentes].

Significado físico de la probabilidad. Bajo las condiciones dadas en el párrafo precedente la


probabilidad adquiere un significado físico del que vamos a hablar ahora. En efecto la

$$P(X \in [a, b]) = F(b) - F(a) = \int_a^b f(x) dx = \int_{[a, b]} f dx$$


pero la integral de Riemann tiene el sentido de una superficie, más concretamente, la probabili-

(7)

dad descrita es el área comprendida bajo la curva $y=f(x)$ en el intervalo $[a, b]$.



Obsérvese que como F es absolutamente continua, $P(X=a)=0$
 la $P(X \in [a, b]) = P(X \in [a, b]) = P(X \in [a, b]) = P(X \in [a, b])$
 Por otra parte el hecho de que $\int_{-\infty}^{+\infty} f(x) dx = 1$, se-
 ñala que el área encerrada bajo la curva $y=f(x)$
 es igual a la unidad.




Observemos finalmente que, vease la figura,
 $f(x)dx$ es un elemento de área, dicho de otra forma,
 un elemento de probabilidad. $f(x)$ tendrá así el
 sentido de densidad de probabilidad por unidad de longitud,
 se dice un nombre de función de densidad de probabilidad.

EJEMPLOS

I) Sea X una v.a. con f.d. F dada por

$$F(x) = \begin{cases} 0, & x \leq 0 \\ x, & 0 < x \leq 1 \\ 1, & 1 < x \end{cases}$$




La f.d.p., f , vendrá dada por la derivada de F en los puntos de continuidad de F , así

$$f(x) = F'(x) = \begin{cases} 0, & x < 0, x > 1 \\ 1, & 0 < x < 1 \end{cases}$$

f no es continua en $x=0$ y $x=1$. Los valores $f(0)$ y $f(1)$
 pueden definirse de cualquier manera, por ejemplo haciendo
 $f(0)=f(1)=0$, tenemos


$$f(x) = \begin{cases} 1 & 0 < x < 1 \\ 0 & \text{en el resto} \end{cases}$$



Una variable de este tipo se la conoce con el nombre de v.a. uniforme sobre el intervalo $[0, 1]$.

II) Sea X una v.a. que tiene una f.d.p. triangular, es decir

$$f(x) = \begin{cases} x, & 0 < x \leq 1 \\ 2-x, & 1 < x \leq 2 \\ 0, & \text{en el resto} \end{cases}$$



Observemos que $f(x)$ es, en efecto, una f.d.p. por tanto

a) $f(x)$ es no negativa a valores en $\mathbb{R}$

b) el área encerrada bajo su gráfica es 1. Es decir
 $\int_{-\infty}^{+\infty} f(x) dx = 1$

La f.d. F , para la v.a. X vendrá dada por

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


usando una integral de Riemann, por cuanto f es una función continua y portanto integrable Riemann. Así pues

$$F(x) = 0, \text{ si } x \leq 0$$

$$F(x) = \int_0^x t dt = \frac{x^2}{2}, \text{ si } 0 < x \leq 1$$

$$F(x) = \int_0^1 t dt + \int_1^x (2-t) dt = 2x - \frac{x^2}{2} - 1, \text{ si } 1 < x \leq 2$$

$$F(x) = 1, \text{ si } x > 2$$



Si quisieramos calcular la probabilidad del intervalo $[-3, 1.5]$, tendríamos

$$P(-3 < X \leq 1.5) = P(X \leq 1.5) - P(X \leq -3) = \left(2(1.5) - \frac{(1.5)^2}{2} - 1\right) - \left(\frac{(-3)^2}{2}\right) = 0.83$$

III) Sea $k > 0$ una constante, y sea

$$f(x) = \begin{cases} kx(1-x), & 0 < x < 1 \\ 0, & \text{en el resto.} \end{cases}$$

entonces

$$\int_0^1 f(x) dx = k \left[\frac{x^2}{2} - \frac{x^3}{3} \right]_0^1 = k \cdot \left[\frac{1}{2} - \frac{1}{3} \right] = \frac{k}{6}.$$

Tendremos que $f(x)$ define una f.d.p. si $k=6$. En este caso la f.d., F , viene dada por

$$F(x) = 0, \text{ si } x \leq 0$$

$$F(x) = \int_0^x 6t(1-t) dt = 6 \left(\frac{t^2}{2} - \frac{t^3}{3} \right), \text{ si } 0 < x < 1$$

$$F(x) = 1, \text{ si } x \geq 1$$

$$\text{Así, } P(X > .3) = 1 - P(X \leq .3) = 1 - 6 \left[\frac{0.09}{2} - \frac{0.027}{3} \right] = 1 - 6[0.045 - 0.009] = 1 - 6 \times 0.036 = 0.784$$


NOTA:- Debemos señalar que los dos tipos de variables aleatorias estudiadas, continuas y discretas, constituyen sólo una pequeña parte de la clase de todas las v.a.'s. Entre dos tipos, sin embargo, contienen prácticamente todas las variables aleatorias que puedan surgirnos en la práctica. Señalamos también, aunque sin demostrarlo, que cada función de distribución admite una descomposición de la forma

$$F(x) = a \cdot F_d(x) + (1-a) \cdot F_c(x)$$

donde F_d y F_c son ambas funciones de distribución. Concretamente F_d es la f.d. de una v.a. discreta, mientras que F_c es continua (no necesariamente absolutamente continua). De hecho se demuestra que a su vez, F_c admite una descomposición posterior. Veamos un ejemplo que ilustre lo dicho y pruebe de manifiesto una v.a. X , que no es ni discreta, ni continua.

IV) Sea X una v.a. en f.d., F , dada por

$$F(x) = \begin{cases} 0, & x < 0 \\ \frac{1}{2}, & x = 0 \\ \frac{1}{2} + \frac{x}{2}, & 0 < x < 1 \\ 1, & 1 \leq x. \end{cases}$$



Obsérvese que F tiene un salto en $x=0$ y F es continua (de hecho, absolutamente continua) en el intervalo $(0,1)$. F es la f.d. de una v.a. X , que no es ni discreta, ni continua. De acuerdo con lo anterior F puede descomponerse como sigue,

$$F(x) = \frac{1}{2} F_d(x) + \frac{1}{2} F_c(x)$$

donde

$$F_d(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad \text{y} \quad F_c(x) = \begin{cases} 0, & x < 0 \\ x, & 0 \leq x < 1 \\ 1, & 1 \leq x. \end{cases}$$

F_d es la f.d. de una v.a. degenerada en el punto $x=0$. Dada así por tener toda la probabilidad concentrada en un sólo punto. Se trata de una variable aleatoria que toma un sólo valor, a saber, 0 constante. F_c es la f.d. de una v.a. uniforme en el intervalo $(0,1)$.

ALGUNAS VARIABLES ALEATORIAS CONTINUAS

I) NORMAL (o GAUSSIANA).

Se trata de una v.a. cuya f.d.p. viene dada por

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] \quad x \in \mathbb{R}.$$

Con estas características decimos que X se distribuye normal (μ, σ^2) , y lo denotamos mediante $N(\mu, \sigma^2)$, donde μ y σ^2 son llamados parámetros de la distribución, cuyo significado comprendiremos más adelante, en cualquier caso $\mu \in \mathbb{R}$ y $\sigma > 0$.

En el caso en que $\mu=0$ y $\sigma=1$, la distribución normal que se obtiene se la conoce con el nombre de distribución normal Standard o normal tipificada, y se la deniega mediante $N(0,1)$. la función f es una f.d.p. por cuanto:

a) Es continua y portanto medible, y además es finita

b) f es no negativa

c) $I = \int_{-\infty}^{+\infty} f(x) dx = 1.$

a) y b) son inmediatas de comprobar. Para demostrar c) lo haremos comprobando que $I^2=1$. De efecto

$$I^2 = \left[\int_{-\infty}^{+\infty} f(x) dx \right]^2 = \int_{-\infty}^{+\infty} f(x) dx \cdot \int_{-\infty}^{+\infty} f(y) dy = \frac{1}{2\pi\sigma^2} \int_{-\infty}^{+\infty} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx \cdot \frac{1}{\sigma} \int_{-\infty}^{+\infty} \exp\left[-\frac{(y-\mu)^2}{2\sigma^2}\right] dy = \frac{1}{2\pi} \cdot \frac{1}{\sigma} \int_{-\infty}^{+\infty} \exp\left[-\frac{z^2}{2}\right] dz \cdot \frac{1}{\sigma} \int_{-\infty}^{+\infty} \exp\left[-\frac{w^2}{2}\right] dw$$

para llegar a esta última igualdad hemos efectuado el cambio $\frac{x-\mu}{\sigma} = z$ y $\frac{y-\mu}{\sigma} = w$.

Por tanto

$$I^2 = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{-(z^2+w^2)/2} dz dw = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{+\infty} e^{-r^2/2} r dr d\theta$$

obtenida esta última igualdad mediante el cambio a coordenadas polares, a saber

$$r^2 = z^2 + w^2 \quad \parallel \quad z = r \cdot \cos \theta$$

$$\theta = \arctan \frac{w}{z} \quad \parallel \quad w = r \cdot \sin \theta$$

siendo el Jacobiano de la transformación, r .

①

En consecuencia

$$I^2 = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{+\infty} e^{-r^2/2} r dr d\theta = \int_0^{2\pi} \left[-e^{-r^2/2} \right]_0^{+\infty} d\theta = -e^{-r^2/2} \Big|_0^{+\infty} = 1.$$

Entre otras propiedades de interés, la función $f(x)$ es simétrica respecto a μ , por cuanto para

$$x_1 = \mu + k$$

$$x_2 = \mu - k$$


tenemos

$$\left. \begin{aligned} f(x_1) &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{k^2}{2\sigma^2}\right] \\ f(x_2) &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(-k)^2}{2\sigma^2}\right] \end{aligned} \right\} f(x_1) = f(x_2)$$

Se comprueba fácilmente que la función alcanza un máximo para $x=\mu$, y que dicho máximo vale

$$f(\mu) = \frac{1}{\sqrt{2\pi}\sigma}$$

Lo que supone que la forma de la función se altera con los distintos valores de σ , más concreta mente es más abultada o más plana según que σ sea menor o mayor.



Gráficas de la f.d.p. de normales $N(1.5, \sigma^2)$ con $\sigma=0.5$, $\sigma=1$ y $\sigma=2$ respectivamente.

El nombre de normal le viene a esta variable aleatoria del hecho de ser la que describe la mayoría de los fenómenos aleatorios que se encuentran en el campo experimental. No obstante, en su importancia radica en las propias desde límites de curvas de variables aleatorias, en las que se ha mencionado.

La correspondiente función de distribución viene dada por

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

pero hay que señalar que $f(t)$ carece de primitiva y portanto los distintos valores de $F(x)$ se obtienen mediante unas tablas adecuadas, no obstante, las tablas son únicas, concretamente las de la normal tipificada, $N(0,1)$, y no ~~se necesitan~~ una para cada par de valores (μ, σ^2) , por cuanto bastará únicamente cubrir todo el conjunto de posibles valores de dichos parámetros. Esto no supone ningún serio problema a la hora de obtener valores de $F(x)$ para

②

una $N(\mu, \sigma^2)$. En efecto, si nosotros queremos calcular, para $N(\mu, \sigma^2)$,

$$F(x) = \int_{-\infty}^x f(t) dt = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(t-\mu)^2}{2\sigma^2}\right] dt$$

efectuando el cambio $z = \frac{t-\mu}{\sigma}$, tendremos que los límites de integración varían, convirtiéndose en $]-\infty, x']$, con $x' = \frac{x-\mu}{\sigma}$, quedando la integral convertida en

$$\Phi(x') = \Phi\left(\frac{x-\mu}{\sigma}\right) = \int_{-\infty}^{x'} \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{z^2}{2}\right] dz$$

en donde $\Phi(x)$ representa la función de distribución de la $N(0,1)$ cuyos valores aparecen en la tabla.

II) GAMMA.

Se trata de una variable aleatoria cuya función de densidad de probabilidad viene dada por

$$f(x) = \begin{cases} \frac{1}{\Gamma(\alpha)\beta^\alpha} \cdot x^{\alpha-1} e^{-x/\beta} & x > 0 \\ 0 & x \leq 0 \end{cases} \quad \alpha > 0, \beta > 0.$$

donde $\Gamma(\alpha)$ es el valor de la función Gamma correspondiente a α , a decir

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} \cdot e^{-y} dy, \quad \alpha > 0$$

la distribución de la v.a. X se la conoce con el nombre de distribución Gamma y α, β son los parámetros de la distribución. Obviamente $f(x) \geq 0, \forall x \in \mathbb{R}$, y además continua y finita y además

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_{-\infty}^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx = \left[\begin{matrix} x/\beta = y \\ x = \beta y \\ dx = \beta dy \end{matrix} \right] = \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^{\infty} y^{\alpha-1} \cdot e^{-y} \cdot \beta^\alpha dy = \\ &= \frac{1}{\Gamma(\alpha)} \cdot \Gamma(\alpha) = 1. \end{aligned}$$

Los distintos valores de la f.d., F , aparecen también tabulados, presentándose las tablas para diferentes valores de los parámetros α, β . Ello da idea de la dificultad que puede suponer obtener valores de F para cualquier α, β .

Respecto de la función Gamma debemos añadir que sus valores son sencillos de obtener

si α es entero o de la forma $n + \frac{1}{2}$, n natural. En efecto, mediante integración sucesiva por partes, puede verse que

$$\Gamma(\alpha) = (\alpha-1) \cdot \Gamma(\alpha-1) = (\alpha-1)(\alpha-2) \cdot \Gamma(\alpha-2) \dots$$

de manera que para α entero,

$$\Gamma(\alpha) = (\alpha-1)(\alpha-2) \dots 2 \Gamma(1)$$

pero

$$\Gamma(1) = \int_0^{\infty} e^{-y} dy = 1$$

y portanto

$$\Gamma(\alpha) = (\alpha-1)!$$

Para el caso en que $\alpha = n + \frac{1}{2}$, obtenemos $\Gamma(\frac{1}{2})$.

$$\Gamma\left(\frac{1}{2}\right) = \int_0^{\infty} e^{-y} \cdot y^{-\frac{1}{2}} dy$$

haciendo $y = \frac{t^2}{2}$, tendremos $y = \frac{t^2}{2}$, $dy = t dt$, $t \in (0, +\infty)$, y de aquí

$$\Gamma\left(\frac{1}{2}\right) = \int_0^{\infty} \frac{\sqrt{2}}{t} e^{-\frac{t^2}{2}} t dt = \sqrt{2} \int_0^{\infty} e^{-\frac{t^2}{2}} dt$$

pero la integral es la última igualdad dada por $\sqrt{2\pi}$ es la mitad del área que cubre la f.d.p. de la $N(0,1)$ y dicha área es $\frac{1}{2}$, así pues

$$\Gamma\left(\frac{1}{2}\right) = \frac{\sqrt{2} \cdot \sqrt{2\pi}}{2} = \sqrt{\pi}$$

lo que hace explicable, en ocasiones, considerando que $\Gamma(\alpha) = (\alpha-1)!$ para α entero y haciendo extensiva esta relación para cualquier α , de la forma

$$\Gamma\left(-\frac{1}{2}\right) = \left(-\frac{1}{2}\right)! = \sqrt{\pi}.$$

Es muy fácil, a partir de aquí, obtener

$$\Gamma\left(\frac{3}{2}\right) = \frac{1}{2} \Gamma\left(\frac{1}{2}\right) = \frac{\sqrt{\pi}}{2}, \dots$$

Hay dos clases de distribuciones Gamma, que por su importancia y uso han adquirido nombre propio y son:

II.a) JI-QUADRADO

Se trata de un caso particular de la Gamma en la que $\alpha = r/2$, r entero no negativo, $\beta = 2$. La f.d.p. tiene la forma

$$f(x) = \begin{cases} \frac{1}{\Gamma(\frac{r}{2}) 2^{r/2}} \cdot e^{-x/2} \cdot x^{(r/2)-1} & x > 0 \\ 0 & x \leq 0 \end{cases} \quad r \geq 0, \text{ entero}$$

a esta f.d.p. se la designa mediante χ_r^2 , y el parámetro r se conoce como el número de grados de libertad de la distribución, cuyo significado veremos más tarde.

II.b) EXPONENCIAL NEGATIVA

Se define la Gamma para $\alpha = 1$, $\beta = 1/\lambda$ y su f.d.p. es

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & x > 0 \\ 0 & x \leq 0 \end{cases} \quad \lambda > 0.$$

La distribución Gamma y sus derivadas aparecen en estadística cuando se estudian, entre otros, problemas de tiempo de espera. En particular la exponencial negativa está ligada a la distribución de Poisson, para el caso de derivadas de material radiactivo, por cuanto a la distribución de probabilidad de la v.a. que estudia el tiempo transcurrido entre dos impactos consecutivos (véase como ejercicio).

III) BETA

Es una v.a. cuya f.d.p. es de la forma

$$f(x) = \begin{cases} \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \cdot x^{\alpha-1} \cdot (1-x)^{\beta-1} & 0 < x < 1 \\ 0 & \text{en el resto} \end{cases} \quad x > 0, \beta > 0.$$

f es una función no negativa, continua, excepto en el punto 1, finita y además normalizada, pues

$$\Gamma(\alpha)\Gamma(\beta) = \left(\int_0^\infty x^{\alpha-1} \cdot e^{-x} dx \right) \cdot \left(\int_0^\infty y^{\beta-1} \cdot e^{-y} dy \right) = \int_0^\infty \int_0^\infty x^{\alpha-1} y^{\beta-1} \cdot e^{-(x+y)} dx dy$$

haciendo el cambio $u = x/(x+y)$, tendremos

$$x = \frac{uy}{1-u}, \quad dx = \frac{y du}{1-u^2}, \quad u \in (0,1) \quad y \quad x+y = \frac{y}{1-u}$$

lo que nos lleva a

$$\begin{aligned} \Gamma(\alpha)\Gamma(\beta) &= \int_0^\infty \int_0^\infty \frac{u^{\alpha-1}}{(1-u)^{\alpha-1}} \cdot y^{\alpha-1} \cdot y^{\beta-1} \cdot e^{-y/(1-u)} \cdot \frac{du}{(1-u)} dy = \\ &= \int_0^\infty \int_0^\infty \frac{u^{\alpha-1}}{(1-u)^{\alpha+1}} y^{\alpha+\beta-1} \cdot e^{-y/(1-u)} du dy \end{aligned}$$

haciendo ahora $y/(1-u) = v$, tendremos $y = v(1-u)$, $dy = (1-u)dv$, $v \in (0, \infty)$. Entonces la integral es

$$\begin{aligned} \Gamma(\alpha)\Gamma(\beta) &= \int_0^\infty \int_0^\infty u^{\alpha-1} (1-u)^{\beta-1} v^{\alpha+\beta-1} \cdot e^{-v} du dv = \\ &= \int_0^\infty v^{\alpha+\beta-1} \cdot e^{-v} dv \cdot \int_0^\infty u^{\alpha-1} (1-u)^{\beta-1} du = \Gamma(\alpha+\beta) \int_0^\infty u^{\alpha-1} (1-u)^{\beta-1} du \end{aligned}$$

se ve que

$$\int_{-\infty}^{\infty} f(x) dx = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)} \cdot \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} = 1.$$

La distribución de probabilidad de X se conoce con el nombre de distribución beta, y debido al hecho de que en Análisis la integral $\int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx$, $\alpha, \beta > 0$ se conoce como la función beta. A α, β se les conoce como los parámetros de distribución. Para la obtención de los valores de $F(x)$ vale todo lo dicho en el correspondiente apartado de la distribución Gamma.

Observación. Para $\alpha = \beta = 1$, tenemos en cuenta que $\Gamma(1) = \Gamma(2) = 1$, la f.d.p. adquiere

la forma

$$f(x) = \begin{cases} 1 & 0 < x < 1 \\ 0 & \text{en el resto} \end{cases}$$

que es la f.d.p. de la v.a. uniforme en el intervalo $[0,1]$.

IV) Cauchy

La f.d.p. viene dada por

$$f(x) = \frac{\sigma}{\pi} \cdot \frac{1}{\sigma^2 + (x-\mu)^2}, \quad x \in \mathbb{R}, \mu \in \mathbb{R}, \sigma > 0$$

Se trata, efectivamente, de una f.d.p. por cumplir todas las propiedades exigibles (7)
 particular. En particular

$$\int_{-\infty}^{+\infty} f(x) dx = \frac{1}{\sigma} \int_{-\infty}^{+\infty} \frac{1}{\sigma^2 + (x-\mu)^2} dx = \frac{1}{\sigma} \int_{-\infty}^{+\infty} \frac{1}{1 + \left(\frac{x-\mu}{\sigma}\right)^2} dx$$

haciendo el cambio $y = \frac{x-\mu}{\sigma}$, $dx = \sigma dy$, y tenemos

$$\int_{-\infty}^{+\infty} f(x) dx = \frac{1}{\sigma} \int_{-\infty}^{+\infty} \frac{\sigma dy}{1+y^2} = \frac{1}{\sigma} [\arctan y]_{-\infty}^{+\infty} = 1$$

Una distribución de probabilidad de estas características se la conoce con el nombre de distribución de Cauchy y μ y σ son los parámetros de la distribución.

La correspondiente gráfica de la f.d.p. se asemeja mucho a la de la normal con igual valor de μ y σ , con la diferencia que aquella tiene las colas más elevadas.

V) LOGNORMAL

Se trata de una variable aleatoria con f.d.p. dada por

$$f(x) = \begin{cases} \frac{1}{x\beta\sqrt{2\pi}} \exp\left[-\frac{(\log x - \log \alpha)^2}{2\beta^2}\right], & x > 0 \\ 0 & x \leq 0, \text{ con } \alpha, \beta > 0. \end{cases}$$

la función $f(x)$ es continua, no negativa, finita y además

$$\int_{-\infty}^{+\infty} f(x) dx = \frac{1}{\beta\sqrt{2\pi}} \int_0^{+\infty} \frac{1}{x} \exp\left[-\frac{(\log x - \log \alpha)^2}{2\beta^2}\right] dx$$

haciendo el cambio $x = e^y$, $\log x = y$, $dx = e^y dy$, $y \in (-\infty, +\infty)$, tenemos

$$\begin{aligned} \int_{-\infty}^{+\infty} f(x) dx &= \frac{1}{\beta\sqrt{2\pi}} \int_{-\infty}^{+\infty} \frac{1}{e^y} \exp\left[-\frac{(y - \log \alpha)^2}{2\beta^2}\right] e^y dy = \\ &= \frac{1}{\beta\sqrt{2\pi}} \int_{-\infty}^{+\infty} \exp\left[-\frac{(y - \log \alpha)^2}{2\beta^2}\right] dy \end{aligned}$$

pero observemos que se trata de la integral de la f.d.p. de una normal, $N(\log \alpha, \beta^2)$ y por tanto dicha integral debe de ser la unidad. Pensamos en el nombre de lognormal, con que se conoce a esta distribución, deriva del hecho expuesto, que decir que X se distribuye como una lognormal es lo mismo que decir que $Y = \log X$ lo hace como una normal. Los constantes α y β se las conoce como los parámetros de la distribución.

EXERCICIOS

I). Si X es una v.a. distribuida $N(3, 0.25)$, obtener, mediante las tablas, las siguientes probabilidades

a) $P(X < -1)$, b) $P(X > 2.5)$, c) $P(-0.5 < X < 1.3)$.

Las tablas son de una normal tipificada y debemos por tanto efectuar el correspondiente cambio para poder utilizarlas. Tendremos pues:

a) $P(X < -1) = P\left(\frac{X-3}{0.5} < \frac{-1-3}{0.5}\right) = P(Z < -8) = \Phi(-8) \approx 0.$

b) $P(X > 2.5) = P\left(\frac{X-3}{0.5} > \frac{2.5-3}{0.5}\right) = P(Z > -1) = 1 - P(Z \leq -1) = 1 - \Phi(-1) = 0.841345$

c) $P(-0.5 < X < 1.3) = P\left(\frac{-0.5-3}{0.5} < \frac{X-3}{0.5} < \frac{1.3-3}{0.5}\right) = P(-7 < Z < -3.4) = \Phi(-3.4) - \Phi(-7) = 0.000337.$

II) Si una v.a. X se distribuye $N(\mu, \sigma^2)$ encontrar, en términos de μ y σ , el valor de c tal que $P(X < c) = 2 - 9 \cdot P(X > c)$.

$$P(X < c) = 2 - 9 \cdot P(X > c) = 2 - 9[1 - P(X \leq c)] = 2 - 9 + 9 \cdot P(X \leq c)$$

$$9 \cdot P(X < c) - P(X < c) = 7 \rightarrow 8 \cdot P(X < c) = 7 \rightarrow P(X < c) = 0.875$$

luego

$$P\left(\frac{X-\mu}{\sigma} < \frac{c-\mu}{\sigma}\right) = 0.875 \text{ es decir } \Phi\left(\frac{c-\mu}{\sigma}\right) = 0.875$$

buscando en las tablas, encontramos

$$\Phi(1.15) = 0.875 \rightarrow \frac{c-\mu}{\sigma} = 1.15 \rightarrow \boxed{c = 1.15\sigma + \mu}$$

III) Un cierto proceso de manufactura produce bombillas, cuya duración, en horas, es una v.a. X distribuida como $N(2000, 200)$. Se supone que una bombilla es defectuosa si su duración es menor de 1800 horas. Si se comprueban 25 bombillas, ¿cuál es la probabilidad de que al menos 15 de ellas, son defectuosas?

El hecho de que las distintas comprobaciones son independientes, para que sea posible, el número de bombillas defectuosas es una distribución binomial, $B(25, p)$, donde p se obtiene a partir de la $N(2000, 200)$ mediante

$$p = P(X < 1800) = P\left(\frac{X-2000}{\sqrt{200}} < \frac{1800-2000}{\sqrt{200}}\right) = P(Z < -\sqrt{200}) = \Phi(-\sqrt{200}) \approx 0$$

y por tanto la probabilidad pedida será cero.

IV) Un proceso de fabricación produce bolas de volcamento de $\frac{1}{2}$ pulgadas que se suponen buenas (1) si su diámetro cae en el intervalo 0.5 ± 0.0006 y defectuosas en cualquier otro caso. La producción de un día se examina y se encuentra que la distribución de los diámetros es aproximadamente normal con media $\mu = 0.5007$ pulgadas y $\sigma = 0.0005$ pulgadas. a) Calcular la proporción de bolas defectuosas. b) Si ajuste menor del proceso permitiera cambiar el diámetro de las bolas, pero no se observara típica, indicar cuál sería el cambio aconsejable y calcular entonces la fracción de bolas defectuosas.

a) Las bolas defectuosas son aquellas cuyo diámetro caen fuera del intervalo 0.5 ± 0.0006 , entonces la proporción buscada, p , vendrá dada por (X representa el diámetro)

$$p = P(X < 0.4994) + P(X > 0.5006) = P\left(\frac{X - 0.5007}{0.0005} < \frac{0.4994 - 0.5007}{0.0005}\right) + P\left(\frac{X - 0.5007}{0.0005} > \frac{0.5006 - 0.5007}{0.0005}\right) = P(Z < -\frac{13}{5}) + P(Z > -\frac{1}{5}) = \Phi(-2.6) + \Phi(-0.2) = 0.004661 + 0.579260 = 0.583921$$

b) Disminuyendo el diámetro medio hasta 0.5 pulgadas, tendríamos

$$p = P(Z < -\frac{5}{5}) + P(Z > \frac{5}{5}) = 2 \cdot P(Z < -1.2) = 2 \cdot (0.116070) = 0.232140.$$

Cualquier otro diámetro medio, puede comportarse ^{así} que la proporción de bolas defectuosas.

V) Supongamos que el consumo medio de agua/mes de los residentes de una comunidad sigue una distribución lognormal con $\alpha = 10^4$ pies cúbicos y $\beta = 10^3$ pies cúbicos por mes. Calcular la proporción de residentes que consumen más de 15×10^3 pies cúbicos mensualmente.

$$P(X > 15 \cdot 10^3) = 1 - P(X \leq 15 \cdot 10^3)$$

Sabemos que si X es lognormal (en parámetros α y β , entonces $Y = \log X$ es una distribución $N(\log \alpha, \beta^2)$. Podemos aplicar el problema anterior de una normal calculando la proporción de residentes que consumen más de $\log(15 \times 10^3)$ pies cúbicos de agua mensualmente. Así pues

$$P(Y > \log(15 \times 10^3)) = 1 - P(Y \leq \log(15 \times 10^3)) = 1 - P\left(\frac{Y - \log 10^4}{10^3} \leq \frac{\log(15 \times 10^3) - \log(10^4)}{10^3}\right) = 1 - P\left(Z \leq \frac{\log 1.5}{10^3}\right) \approx 1 - \Phi(0) = 1 - 0.5 = 0.5$$

VI) Relación entre las distribuciones de POISSON y EXPONENCIAL NEGATIVA.

Consideremos una variable aleatoria X que denota el número de impactos, producidos de la desintegración de cierto material radiactivo, que alcanzan un contador Geiger en un intervalo de tiempo t . Ya sabemos que se trata de una v.a. con distribución de Poisson con parámetro λt , y por tanto

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

Sea ahora T , una variable que denota el tiempo transcurrido entre dos impactos consecutivos. El suceso $T > t$ representa el hecho de que no se hayan producido impactos durante el intervalo de tiempo t , y por tanto

$$P(T > t) = P(X=0) = e^{-\lambda t}$$

pero por otra parte, si designamos mediante $f(t)$ la f.d.p. de la v.a. T , tendríamos

$$P(T > t) = 1 - P(T \leq t) = 1 - \int_0^t f(x) dx = 1 - \int_0^t f(x) dx = e^{-\lambda t}$$

derivando en ambos miembros de la igualdad, llegamos a

$$f(t) = \lambda e^{-\lambda t}, \quad t \geq 0$$

que es la f.d.p. de una exponencial negativa con parámetro λ .

VII) Sea X una v.a. distribuida como $U(-\alpha, \alpha)$. Determinar el valor del parámetro α para que sea cierto lo siguiente:

$$a) P(-1 < X < 2) = 0.75, \quad b) P(1 < X < 1) = P(1 < X < 2)$$

Recordemos que la f.d.p. de una $U(-\alpha, \alpha)$ viene dada por

$$f(x) = \begin{cases} \frac{1}{2\alpha} & -\alpha \leq x \leq \alpha \\ 0 & \text{en el resto.} \end{cases}$$

Por tanto para a)

$$P(-1 < X < 2) = P(X < 2) - P(X \leq -1) = \int_{-\alpha}^2 f(x) dx - \int_{-\alpha}^{-1} f(x) dx = \int_{-1}^2 f(x) dx = \frac{1}{2\alpha} \int_{-1}^2 dx = \frac{2 - (-1)}{2\alpha} = \frac{3}{2\alpha} = 0.75 \rightarrow \alpha = 2$$

para b) tenemos $\frac{1}{2} \frac{d}{dt} \left(\frac{1}{2} \frac{d^2 x}{dt^2} \right) = \frac{1}{4} \frac{d^3 x}{dt^3}$ (11)

$$P(|Z| < 1) = P(-1 < Z < 1) = \int_{-1}^1 f(x) dx = 1/2$$

$$P(|Z| > 2) = P(-\infty < Z < -2) + P(2 < Z < \infty) = \frac{1}{2\pi} \int_{-\infty}^{-2} e^{-\frac{z^2}{2}} dz + \frac{1}{2\pi} \int_2^{\infty} e^{-\frac{z^2}{2}} dz = \frac{\pi-2}{2\pi} + \frac{\pi-2}{2\pi} = \frac{\pi-2}{\pi}$$

entrance

$$\frac{x-2}{x} = \frac{1}{x} \rightarrow x-2=1 \rightarrow \underline{x=3}$$

Capítulo 6

Vectores aleatorios

VECTORES ALEATORIOS

Hagamos en primer lugar algunas consideraciones respecto de β^k . Tanto de Borel en $\mathbb{R}^k$. Demostremos que la tribu de Borel de un espacio topológico viene engendrada por el sistema de abiertos (o cerrados) del espacio en cuestión. No obstante, hay ocasiones en que, si el espacio lo permite, podemos fijar nuestra atención en subfamilias que engendran igualmente dicho tribu. Así por ejemplo, veamos que en el caso de $\mathbb{R}$, β podía venir engendrada por intervalos de la forma $] -\infty, a]$, o de a, ∞ o bien por cualquier otra familia de intervalos. Igual ocurre en $\mathbb{R}^k$, de manera que podemos engendrar β^k a partir de cualquier familia de intervalos, por ejemplo $] -\infty, \vec{x}]$ con $\vec{x} = (x_1, \dots, x_k)$. Pasemos ahora a la definición de vector aleatorio.

Definición. Sea $(S, \mathcal{B}, P)$ un espacio de probabilidad y sea el espacio medible $(\mathbb{R}^k, \beta^k)$.

Definimos entre ambos una aplicación medible $\vec{X}$, a la que denominaremos vector aleatorio.

El concepto de vector aleatorio no es más que una generalización inmediata del concepto de variable aleatoria que ya hemos estudiado. De la definición que acabamos de dar se deriva de inmediato la siguiente propiedad:

Propiedad. Una aplicación $\vec{X}$ de $(S, \mathcal{B}, P)$ en $(\mathbb{R}^k, \beta^k)$ es un vector aleatorio si y

sólo si cada una de sus componentes X_i , $i=1, \dots, k$ es una variable aleatoria.

Demostración. Sea $\vec{X}$ un vector aleatorio y definamos sobre $\mathbb{R}^k$ la función g_i de la forma

$$g_i(x_1, \dots, x_k) = x_i$$

g_i es la proyección y como tal es continua y portanto medible, en consecuencia

$$X_i = g_i(\vec{X})$$

es una variable aleatoria por cuanto resulta de la composición de dos aplicaciones medibles.

Sea ahora las X_i , $i=1, \dots, k$, variables aleatorias. Para demostrar que $\vec{X}$ es un vector aleatorio hemos de comprobar que

$$\vec{X}^{-1}(B) \in \mathcal{B} \quad B \in \beta^k$$

pero teniendo en cuenta las consideraciones iniciales basta con tomar B en una de las familias que engendran β^k , por ejemplo $B =] -\infty, \vec{x}]$, entonces

$$\begin{aligned} \vec{X}^{-1}(B) &= \{s \in S; \vec{X}(s) \in B\} = \{s \in S; X_i(s) \leq x_i, i=1, \dots, k\} \\ &= \bigcap_{i=1}^k \{s \in S; X_i(s) \leq x_i\} = \bigcap_{i=1}^k \{X_i^{-1}(]-\infty, x_i])\} \in \mathcal{B} \end{aligned}$$

y este último conjunto es de $\mathcal{B}$ por verlo cada $X_i^{-1}(]-\infty, x_i])$, ya que las X_i son variables aleatorias.

Probabilidad inducida. A partir de P y mediante $\vec{X}$ podemos definir sobre el espacio medible $(\mathbb{R}^k, \beta^k)$ una medida de probabilidad. En efecto, para cada $B \in \beta^k$

$$P'(B) = P(\vec{X}^{-1}(B)).$$

Análogamente a como lo haríamos en el caso unidimensional podemos ahora definir una función de distribución de probabilidad a partir de esta probabilidad inducida tomando una clase especial de conjuntos de Borel. En efecto, para $B =] -\infty, \vec{x}]$, tenemos

$$F(\vec{x}) = F(x_1, \dots, x_k) = P'(]-\infty, \vec{x}]) = P(\vec{X}^{-1}(]-\infty, \vec{x}])) = P(\vec{X} \leq \vec{x}).$$

De esta definición se derivan, de inmediato, las siguientes propiedades:

- 1) La función $F(\vec{x})$ es continua por la derecha ^{y no decreciente} en cada una de las componentes de $\vec{x}$. La comprobación es sencilla y similar a la presentada en el caso unidimensional.
- 2) Sean $a = (a_1, \dots, a_k)$ y $b = (b_1, \dots, b_k)$, tales que $a \leq b$, es decir $a_i \leq b_i$, $i=1, \dots, k$. El subconjunto de $\mathbb{R}^k$, $\{a \leq b\}$ representa un rectángulo k -dimensional con extremos superior e inferior, b y a respectivamente.

Definamos ahora el siguiente operador Δ_{b-a} que actuará sobre cualquier función definida en $\mathbb{R}^k$ de la siguiente forma


$$\Delta_{b-a} \{F(a_1, \dots, a_i, \dots, a_k)\} = F(a_1, \dots, b_i, \dots, a_k) - F(a_1, \dots, a_i, \dots, a_k).$$

Introducimos también el operador Δ_{b-a} , de la siguiente forma:

$$\Delta_{b-a} \{F(a)\} = \Delta_{b_1-a_1} \Delta_{b_2-a_2} \dots \Delta_{b_k-a_k} \{F(a)\}$$

Así, por ejemplo, para $k=2$, tendríamos

$$\begin{aligned} \Delta_{b-a} \{F(a)\} &= \Delta_{b_1-a_1} \Delta_{b_2-a_2} \{F(a_1, a_2)\} = \Delta_{b_1-a_1} \{F(b_1, b_2) - F(a_1, b_2)\} \\ &= \Delta_{b_1-a_1} \{F(b_1, b_2)\} - \Delta_{b_1-a_1} \{F(a_1, b_2)\} = F(b_1, b_2) - F(a_1, b_2) \\ &\quad - (F(b_1, a_2) - F(a_1, a_2)) = [F(b_1, b_2) - F(b_1, a_2)] - [F(a_1, b_2) - F(a_1, a_2)] \end{aligned}$$



y observando la figura y teniendo en cuenta que $F(\vec{x}) = P(\vec{X} \leq \vec{x})$

llegamos a que $\Delta_{b-a} \{F(a)\} = P(\vec{X} \in [a, b]) \geq 0$

Esta es precisamente la segunda propiedad de $F(\vec{x})$, saber:

Si $a \leq b$, entonces $\Delta_{b-a} \{F(a)\} \geq 0$.

- 3) $\lim_{x_i \rightarrow -\infty} F(x_1, x_2, \dots, x_k) = 0$, para todo x_i .

Se comprueba fácilmente observando que los intervalos de la forma $\{t; t \leq x_i\}$ tienden al vacío a medida que $x_i \rightarrow -\infty$.

- 4) $\lim_{(x_1-x_k) \rightarrow (+\infty, -1, +\infty)} F(x_1, \dots, x_k) = 1$. Por tanto en el límite se trata de obtener la probabilidad $P(\vec{x} \in \mathbb{R}^k)$ que obviamente es la unidad. ③

De la misma forma que para las variables aleatorias, una función de distribución de probabilidad podía utilizarse para inducir una probabilidad sobre los bodeles de $\mathbb{R}$, y en aras de la equivalencia entre ambos conceptos (medida de probabilidad inducida y función de distribución de probabilidad), también aquí podemos actuar de forma semejante pero, ¿o x_i ? Formando algunas precauciones impuestas por los cambios que se han producido en la notación. En otros palabras, la generalización no puede hacerse directamente sino que hay que generalizar cuidadosamente el concepto de función de distribución de probabilidad. Hagámoslo:

Definición: Sea $F(\vec{x})$, $\vec{x} = (x_1, \dots, x_k)$ una función definida sobre $\mathbb{R}^k$. Diremos que $F(\vec{x})$ es una función de distribución de probabilidad si cumple las siguientes condiciones:

- $\Delta_{b-a} \{F(a)\} \geq 0$, si $a \leq b$
- F es creciente y continua por la derecha en cada una de las componentes de $\vec{x}$.
- $\lim_{x_i \rightarrow -\infty} F(x_1, \dots, x_k) = 0$ para cada x_i .
- $\lim_{(x_1-x_k) \rightarrow (+\infty, -1, +\infty)} F(x_1, \dots, x_k) = 1$

Obsérvese que esta definición coincide con la dada para una función de distribución de probabilidad. Sin embargo ahora hemos debido especificar la condición C.1) por cuanto la monotonía y la continuidad no bastan para que $F(\vec{x})$ pueda utilizarse en la definición de una probabilidad sobre $\mathbb{R}^k$ de $\mathbb{R}^k$. Consideremos el ejemplo que sigue para mejor comprender lo dicho.

Ejemplo 1. Sea $F(x, y)$ definida como sigue

$$F(x, y) = \begin{cases} 0, & \text{si } x < 0 \text{ o } x+y < 1, \text{ o } y < 0 \\ 1, & \text{en el resto} \end{cases}$$


Esta función satisface las condiciones C.2, C.3, C.4 de la anterior definición. Sean $a = (\frac{1}{3}, \frac{1}{3})$, $b = (1, 1)$, entonces

$$\Delta_{b-a} \{F(a)\} = F(1, 1) + F(\frac{1}{3}, \frac{1}{3}) - F(1, \frac{1}{3}) - F(\frac{1}{3}, 1) = 1 + 0 - 1 - 1 = -1 < 0.$$

por tanto no podemos utilizar $F(\vec{x})$ para la definición de una medida de probabilidad sobre $\mathbb{R}^k$ de $\mathbb{R}^k$ sobre la base de hacerlo mediante

$$P([a, b]) = \Delta_{b-a} \{F(a)\},$$

por cuanto nos encontramos con que $P([a, b]) = -1 < 0$, para $a = (\frac{1}{3}, \frac{1}{3})$, $b = (1, 1)$.



El punto de una función de distribución de probabilidad, como la definida, ④
podemos definir una medida de probabilidad sobre $\mathbb{R}^k$ de $\mathbb{R}^k$, haciendo lo en primera instancia sobre la familia de los intervalos de la forma $\{x; a < x \leq b\} = [a, b]$, mediante $P([a, b]) = \Delta_{b-a} \{F(a)\}$.

Continuando, mediante el teorema de extensión, podemos hacer que la medida P trabaje sobre $\mathbb{R}^k$. En definitiva esto viene a pasar de manifestar la equivalencia entre ambos conceptos a la hora de construir las características de la distribución de probabilidad del vector aleatorio $\vec{x}$.

Así, al igual que cuando con las variables aleatorias, diversos tipos de vectores aleatorios. Ahora tan sólo nos ocuparemos de los dos más interesantes y que son los equivalentes a las variables aleatorias estudiadas anteriormente.

Tipos de vectores aleatorios: Como hicimos en el caso unidimensional podemos ahora introducir una nueva función, a saber

$$f(\vec{x}) = F(x_1, \dots, x_k) - P(\vec{x} = \vec{x}) = P(\vec{x}_1 = x_1, \dots, \vec{x}_k = x_k).$$

Sea $A = \{\vec{x} \in \mathbb{R}^k; f(\vec{x}) > 0\}$, si A es tal que

$$\sum_{\vec{x} \in A} f(\vec{x}) = 1$$

decimos entonces que $\vec{x}$ es un vector aleatorio discreto. Obsérvese que tal y como ocurría en el caso unidimensional A es also sumo numerable. A la función f se la denomina función de densidad y quando con F la siguiente relación:

$$F(\vec{x}) = \sum_{\vec{t} \in A \cap [-\infty, \vec{x}]} f(\vec{t})$$

Lo que supone que la $F(\vec{x})$ es el equivalente k -dimensional a una función en $\mathbb{R}$.

Un momento similar al utilizado en el caso unidimensional, (que no utilizaremos aquí, no lleva a introducir el concepto de vector aleatorio continuo, como aquel para el que existe una función f , tal que, siendo no negativa,

$$F(\vec{x}) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_k} f(t_1, \dots, t_k) dt_1 \dots dt_k.$$

a la función f se la designa como función de densidad de probabilidad. Todas las consideraciones de tipo general que en su momento hicimos para las variables aleatorias son aplicables ahora, substituyendo hipervolumen k -dimensional, donde decimos más aún, etc. ...

La función de densidad de probabilidad tiene, como consecuencia de la definición, las ~~siguientes~~ propiedades siguientes:

a) Si f es continua en $(x_1, x_2, \dots, x_k)$, entonces

$$F(x_1, \dots, x_k) = \frac{\partial^k F(x_1, \dots, x_k)}{\partial x_1 \dots \partial x_k}$$

b)

$$\begin{aligned} \lim_{(x_1, \dots, x_k) \rightarrow (+\infty, \dots, +\infty)} F(x_1, \dots, x_k) &= 1 = \lim_{(x_1, \dots, x_k) \rightarrow (+\infty, \dots, +\infty)} \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_k} f(t_1, \dots, t_k) dt_1 \dots dt_k \\ &= \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f(x_1, \dots, x_k) dx_1 \dots dx_k. \end{aligned}$$

De acuerdo con todo lo expuesto, y dado que la distribución de probabilidad de un vector aleatorio $\vec{X}$ podemos conocerla a través de su función de distribución, en algunas ocasiones también podemos conocer, y por tanto caracterizar, dicha distribución a partir de la función de densidad de probabilidad.

Ejemplo 2.- Sea X una variable aleatoria cuyo valor designe la cara que nos muestre un dado al ser lanzado. Sea Y una variable aleatoria que tome los valores 0 o 1, según que una moneda, previamente lanzada, nos muestre su cara o su cruz. Tanto el dado como la moneda son perfectos y los lanzamientos independientes. Definiremos un vector aleatorio mediante (X, Y) . Dicho vector será del tipo discreto con

$$A = \{(1,0), (2,0), \dots, (6,0), (1,1), \dots, (6,1)\}$$

$$y f(x_1, x_2) = \frac{1}{12} \text{ para } (x_1, x_2) \in A.$$

La función de distribución viene dada por

$$F(x, y) = \begin{cases} 0 & x < 1, -\infty < y < +\infty; -\infty < x < +\infty, y < 0 \\ 1/12 & 1 \leq x < 2, 0 \leq y < 1 \\ 1/6 & 2 \leq x < 3, 0 \leq y < 1; 1 \leq x < 2, 1 \leq y \\ 1/4 & 3 \leq x < 4, 0 \leq y < 1 \\ 1/3 & 4 \leq x < 5, 0 \leq y < 1; 2 \leq x < 3, 1 \leq y \\ 5/12 & 5 \leq x < 6, 0 \leq y < 1 \end{cases}$$

$$F(x, y) = \begin{cases} 1/2 & 6 \leq x < 7, 0 \leq y < 1; 3 \leq x < 4, 1 \leq y \\ 2/3 & 4 \leq x < 5, 1 \leq y \\ 5/6 & 5 \leq x < 6, 1 \leq y \\ 1 & 6 \leq x, 1 \leq y \end{cases}$$

Ejemplo 3.- Sea (X, Y) un vector aleatorio del tipo continuo. Una función de densidad de probabilidad dada por

$$f(x, y) = \begin{cases} e^{-(x+y)} & 0 < x < +\infty, 0 < y < +\infty \\ 0 & \text{en el resto.} \end{cases}$$

Efectivamente $f(x, y)$ es una f.d.p. por cuanto

$$a) f(x, y) \geq 0 \quad \forall (x, y)$$

$$b) \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) dx dy = \int_0^{+\infty} \int_0^{+\infty} e^{-(x+y)} dx dy = \left[(1 - e^{-x}) \right]_0^{+\infty} \int_0^{+\infty} e^{-y} dy = [1 - e^{-y}]_0^{+\infty} = 1$$

Así pues la función de distribución del vector aleatorio (X, Y) será

$$F(x, y) = \int_0^x \int_0^y e^{-(t+u)} dt du = (1 - e^{-x})(1 - e^{-y}) \quad \begin{matrix} 0 < x < +\infty \\ 0 < y < +\infty \end{matrix}$$

$$F(x, y) = 0 \quad \text{en el resto.}$$

Funciones de distribución y de densidad marginales

Sea $\vec{X}$ un vector aleatorio y sea $F(\vec{x})$ su función de distribución. Consideremos los dos subvectores $\vec{x}_1$ y $\vec{x}_2$ de dimensiones m y $k-m$ respectivamente, $m \geq 1$, de manera que $\vec{x} = (\vec{x}_1, \vec{x}_2)$ ya sabemos que como tales vectores también serán aleatorios. Consideremos la función de distribución en un pto. genérico $\vec{x} = (\vec{x}_1, \vec{x}_2)$ y supongamos que $\vec{x}_2 \rightarrow +\infty$ entonces sus componentes tenderán

$$\begin{aligned} F(\vec{x}_1, +\infty, \dots, +\infty) &= \lim_{\vec{x}_2 \rightarrow (+\infty, \dots, +\infty)} F(\vec{x}_1, \vec{x}_2) = \lim_{\vec{x}_2 \rightarrow (+\infty, \dots, +\infty)} P(\vec{x}_1 \leq \vec{x}_1, \vec{x}_2 \leq \vec{x}_2) = P(\vec{x}_1 \leq \vec{x}_1) \\ &= F_{\vec{x}_1}(\vec{x}_1) \end{aligned}$$

es decir, resulta de la función de distribución del subvector $\vec{x}_1$. Actuando de esta manera podremos obtener la función de distribución de cualquier subvector de dimensión $m \leq k$. De particular para $m=1$, tendremos las funciones de distribución de las variables aleatorias que componen el vector $\vec{X}$, a saber

$$F_i(x_i) = F(+\infty, \dots, x_i, \dots, +\infty).$$

observase que para cada dimensión m , con exactamente $\binom{k}{m}$ el número de subvectores de dimensión m que pueden obtenerse. A todas estas funciones de distribución, así obtenidas,

se los conoce con el nombre de función de distribución marginal (del subvector correspondiente $\vec{X}_1$). Por contraposición con esta nomenclatura a $F(\vec{x}) = F(x_1, \dots, x_n)$ se la conoce con el nombre de función de distribución conjunta.

Si $\vec{X}$ es un vector aleatorio discreto, recordemos que, si A es tal que $P(\vec{X} \in A) = 1$, tendríamos

$$F(\vec{x}) = \sum_{\vec{t} \in A \cap]-\infty, \vec{x}] } f(\vec{t}), \text{ con } f(\vec{t}) = P(\vec{X} = \vec{t})$$

entonces de los subvectores $\vec{X}_1$ y $\vec{X}_2$ la anterior expresión podría escribirse

$$F(\vec{x}_1, \vec{x}_2) = \sum_{(\vec{t}_1, \vec{t}_2) \in A \cap]-\infty, \vec{x}] } f(\vec{t}_1, \vec{t}_2) = \sum_{\vec{t}_1 \in A_1 \cap]-\infty, \vec{x}_1]} \left[\sum_{\vec{t}_2 \in A_2 \cap]-\infty, \vec{x}_2]} f(\vec{t}_1, \vec{t}_2) \right]$$

donde A_i es la proyección de A en el subespacio correspondiente, es igual que $]-\infty, \vec{x}_i]$, $i=1,2$. En esta situación

$$\begin{aligned} F_{\vec{X}_1}(\vec{x}_1) &= \lim_{\vec{x}_2 \rightarrow +\infty} F(\vec{x}_1, \vec{x}_2) = \lim_{\vec{x}_2 \rightarrow +\infty} \left\{ \sum_{\vec{t}_1 \in A_1 \cap]-\infty, \vec{x}_1]} \left[\sum_{\vec{t}_2 \in A_2 \cap]-\infty, \vec{x}_2]} f(\vec{t}_1, \vec{t}_2) \right] \right\} = \\ &= \sum_{\vec{t}_1 \in A_1 \cap]-\infty, \vec{x}_1]} \left[\sum_{\vec{t}_2 \in A_2} f(\vec{t}_1, \vec{t}_2) \right] = \sum_{\vec{t}_1 \in A_1 \cap]-\infty, \vec{x}_1]} f_{\vec{X}_1}(\vec{t}_1) \end{aligned}$$

donde $f_{\vec{X}_1}(\vec{t}_1) = \sum_{\vec{t}_2 \in A_2} f(\vec{t}_1, \vec{t}_2)$ es la función de cuantía del vector aleatorio $\vec{X}_1$, como fácilmente se desprende de las últimas igualdades antes. Al igual que a su correspondiente función de distribución también a ésta se la conoce como la marginal ~~función~~ función de cuantía marginal, mientras que a la $f(\vec{x}) = f(x_1, \dots, x_n)$ se la denomina función de cuantía conjunta.

Supongamos que el vector $\vec{X}$ es continuo, es decir, existe f tal que

$$F(\vec{x}) = F(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f(t_1, \dots, t_n) dt_1 \dots dt_n$$

o bien, adoptando una nomenclatura adecuada con los subvectores $\vec{X}_1$ y $\vec{X}_2$,

$$F(\vec{x}_1, \vec{x}_2) = \int_{\vec{t}_1 \in \vec{X}_1} \int_{\vec{t}_2 \in \vec{X}_2} f(\vec{t}_1, \vec{t}_2) d\vec{t}_2 d\vec{t}_1$$

Para la obtención de la función de distribución marginal de $\vec{X}_1$, tendríamos

$$F_{\vec{X}_1}(\vec{x}_1) = \lim_{\vec{x}_2 \rightarrow +\infty} F(\vec{x}_1, \vec{x}_2) = \int_{\vec{t}_1 \in \vec{X}_1} \left[\int_{\vec{t}_2 \in \mathbb{R}^{n-m}} f(\vec{t}_1, \vec{t}_2) d\vec{t}_2 \right] d\vec{t}_1$$

de acuerdo con esto lo que figura dentro del corchete debe ser la función de densidad marginal del subvector aleatorio $\vec{X}_1$, es decir

$$f_{\vec{X}_1}(\vec{x}_1) = \int_{\vec{x}_2 \in \mathbb{R}^{n-m}} f(\vec{x}_1, \vec{x}_2) d\vec{x}_2 = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} f(x_1, \dots, x_m, x_{m+1}, \dots, x_n) dx_{m+1} \dots dx_n$$

veamos un par de ejemplos.

Ejemplo 4. Lanzamos tres veces una moneda. Sea X la variable que representa el número de caras en los tres lanzamientos e Y la diferencia, en valor absoluto, entre el número de caras y el número de cruces. Obtener las funciones de cuantía conjunta y marginales y las de distribución.

Para mejor trabajar dispondremos los valores en la siguiente tabla:

$Y \backslash X$	0	1	2	3	$P(Y=y)$
1	0	3/8	3/8	0	6/8
3	1/8	0	0	1/8	2/8
$P(X=x)$	1/8	3/8	3/8	1/8	1

La función de cuantía conjunta con los valores que aparecen en el centro de la tabla. Las marginales los que aparecen en los márgenes de la misma.

Las funciones de distribución se obtendrán sumando adecuadamente. Así por ejemplo, para la conjunta


$$F(2.5, 1.5) = P(X \leq 2.5, Y \leq 1.5) = \sum_{\substack{x \in \{0,1,2\} \\ y \in \{1\}}} f(x, y) = f(0,1) + f(1,1) + f(2,1) = 6/8$$

Para la marginal de la X

$$F_X(2.5) = P(X \leq 2.5) = P(X=0) + P(X=1) + P(X=2) = 7/8$$

Ejemplo 5. Supongamos un vector aleatorio bidimensional (X_1, X_2) con función de densidad de probabilidad conjunta

$$f(x_1, x_2) = \begin{cases} 2, & 0 < x_1 < x_2 < 1 \\ 0, & \text{en el resto} \end{cases}$$



Las funciones de densidad marginales vienen dadas por

$$f_1(x_1) = \int_{-\infty}^{+\infty} f(x_1, x_2) dx_2 = \int_{x_1}^1 2 dx_2 = 2(1-x_1) \quad 0 < x_1 < 1$$

$$f_1(x_1) = 0 \quad \text{en el resto}$$

$$f_2(x_2) = \int_0^{x_2} 2 dx_1 = 2x_2, \quad 0 < x_2 < 1$$

$$f_2(x_2) = 0 \quad \text{en el resto.}$$

la función de distribución conjunta viene dada por

$$F(x_1, x_2) = 0 \quad \text{si } x_1 \leq 0 \text{ o } x_2 \leq 0$$

$$F(x_1, x_2) = \int_0^{x_1} \int_0^{x_2} f(t_1, t_2) dt_2 dt_1 = \int_0^{x_1} \int_0^{x_2} 2 dt_2 dt_1 = 2 \int_0^{x_1} (x_2 - t_1) dt_1 = 2 \left(x_2 x_1 - \frac{x_1^2}{2} \right) =$$

$$= x_1(2x_2 - x_1) \quad 0 < x_1 < x_2 < 1$$

$$F(x_1, x_2) = 2x_1 - x_1^2, \quad 0 < x_1 < 1, x_2 \geq 1$$

$$F(x_1, x_2) = x_2^2, \quad 0 < x_2 < 1, x_1 \geq x_2$$

$$F(x_1, x_2) = 1, \quad x_1 \geq 1, x_2 \geq 1.$$

los marginales son, para $\mathcal{X}_1$

$$F_{\mathcal{X}_1}(x_1) = \int_0^{x_1} (2 - 2t_1) dt_1 = 2x_1 - x_1^2, \quad 0 < x_1 < 1$$

$$F_{\mathcal{X}_1}(x_1) = 1, \quad x_1 \geq 1$$

$$F_{\mathcal{X}_1}(x_1) = 0, \quad x_1 \leq 0$$


para $\mathcal{X}_2$

$$F_{\mathcal{X}_2}(x_2) = 0, \quad x_2 \leq 0$$

$$F_{\mathcal{X}_2}(x_2) = \int_0^{x_2} 2t_2 dt_2 = x_2^2, \quad 0 < x_2 < 1$$

$$F_{\mathcal{X}_2}(x_2) = 1, \quad x_2 \geq 1$$

la figura pone de manifiesto conjuntamente, todos estos resultados



9 Función de densidad y de distribución condicionada.

(10)

Caso directo. Sea $\vec{X}$ un vector aleatorio discreto y considere un muestreo sucesivo en dos subvectores $(\vec{X}_1, \vec{X}_2) = \vec{X}$. Sea además $\vec{X}_1 = \vec{x}_1$ de manera que $f_{\vec{X}_1}(\vec{x}_1) > 0$, definamos una nueva función, del subvector $\vec{X}_2$, mediante

$$f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1) = \frac{f(\vec{x}_1, \vec{x}_2)}{f_{\vec{X}_1}(\vec{x}_1)}$$

Así definida esta función tiene las siguientes propiedades:

$$a) f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1) \geq 0, \quad f_{\vec{X}_2}$$

$$b) \int_{\vec{X}_2} f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1) = \int_{\vec{X}_2} \frac{f(\vec{x}_1, \vec{x}_2)}{f_{\vec{X}_1}(\vec{x}_1)} = \frac{1}{f_{\vec{X}_1}(\vec{x}_1)} \left[\int_{\vec{X}_2} f(\vec{x}_1, \vec{x}_2) \right] =$$

$$= \frac{1}{f_{\vec{X}_1}(\vec{x}_1)} \cdot f_{\vec{X}_1}(\vec{x}_1) = 1$$

pero estas con las condiciones que definen a las funciones de densidad de probabilidad, es decir $f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1)$ es una f.d.p., pero ¿que significado tiene? Veámoslo.

Recordemos que $f(\vec{x}_1, \vec{x}_2) = P(\vec{X}_1 = \vec{x}_1, \vec{X}_2 = \vec{x}_2)$ y $f_{\vec{X}_1}(\vec{x}_1) = P(\vec{X}_1 = \vec{x}_1)$, así pues

$$f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1) = \frac{P(\vec{X}_1 = \vec{x}_1, \vec{X}_2 = \vec{x}_2)}{P(\vec{X}_1 = \vec{x}_1)} = P(\vec{X}_2 = \vec{x}_2 / \vec{X}_1 = \vec{x}_1)$$

la función representa pues la probabilidad condicional de que el subvector $\vec{X}_2$ tome el valor $\vec{x}_2$ si el subvector $\vec{X}_1$ toma el valor $\vec{x}_1$. Obsérvese además que

$$P(\vec{X}_2 \in B / \vec{X}_1 = \vec{x}_1) = \int_{\vec{X}_2 \in B} P(\vec{X}_2 \in B / \vec{X}_1 = \vec{x}_1) = \int_{\vec{X}_2 \in B} f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1)$$

Definitivamente, $f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1)$ es la función de densidad condicionada de $\vec{X}_2$, dado que $\vec{X}_1 = \vec{x}_1$.

Análogamente se define $f_{\vec{X}_1/\vec{X}_2}(\vec{x}_1/\vec{x}_2)$ siempre que $\vec{x}_2$ tal que $f_{\vec{X}_2}(\vec{x}_2) > 0$.

Ejemplo 6. Revisemos el vector aleatorio bidimensional del ejemplo 4. Algunos de los ⁽¹¹⁾ condicionados que allí pueden definirse serán, por ejemplo

$$f_{x/y=1}(x/1) = 0 \quad , \quad \text{para } x=0, x=3$$

$$f_{x/y=1}(x/1) = \frac{1}{2} \quad , \quad \text{para } x=1, x=2$$

$$f_{x/y=3}(x/3) = \frac{1}{2} \quad , \quad \text{para } x=0, x=3$$

$$f_{x/y=3}(x/3) = 0 \quad , \quad \text{para } x=1, x=2$$

$$f_{y/x=0}(y/0) = 0 \quad , \quad \text{para } y=1$$

$$f_{y/x=0}(y/0) = 1 \quad , \quad \text{para } y=3$$

El vector aleatorio condicionado $\vec{X}_2/\vec{X}_1=\vec{x}_1$ tiene como función de distribución condicional a $F_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1)$, cuyo valor es función de la función de densidad condicionada y

$$F_{\vec{X}_2/\vec{X}_1}(\vec{x}_2/\vec{x}_1) = \int_{\vec{t}_2 \leq \vec{x}_2} f_{\vec{X}_2/\vec{X}_1}(\vec{t}_2/\vec{x}_1) d\vec{t}_2$$

Así por ejemplo, en el caso anterior tendríamos

$$F_{x/y=1}(2/1) = \int_{t \leq 2} f_{x/y=1}(t/1) dt = f_{x/y=1}(0/1) + f_{x/y=1}(1/1) + f_{x/y=1}(2/1) = 0 + \frac{1}{2} + \frac{1}{2} = 1.$$

Caso continuo - Supongamos ahora que $\vec{X}$ es un vector aleatorio del tipo continuo y para facilitar el desarrollo que vamos a continuación vamos a situarnos en el caso bidimensional, es decir, $\vec{X} = (X, Y)$. Revisemos que en el caso continuo $P(X=x)=0$, $P(Y=y)=0$ y por tanto ahora, probabilidades del tipo $P(X \leq x / Y=y)$ no están definidas. Sea entonces $\varepsilon > 0$ y supongamos que $P(Y-\varepsilon < Y \leq Y+\varepsilon) > 0$, definiremos entonces la siguiente probabilidad condicional,

$$P(X \leq x / Y-\varepsilon < Y \leq Y+\varepsilon) = \frac{P(X \leq x, Y-\varepsilon < Y \leq Y+\varepsilon)}{P(Y-\varepsilon < Y \leq Y+\varepsilon)}.$$

Se trata, para haberlo intentado fijo $Y-\varepsilon, Y+\varepsilon$, la probabilidad condicional de que $X \leq x$, dado que $Y \in [Y-\varepsilon, Y+\varepsilon]$, es decir, de la función de distribución condicional de X , dado que $Y \in [Y-\varepsilon, Y+\varepsilon]$.

Consideremos ahora el siguiente límite

$$\lim_{\varepsilon \rightarrow 0^+} P(X \leq x / Y \in [Y-\varepsilon, Y+\varepsilon]).$$

Cuando dicho límite existe lo designaremos mediante $F_{x/y}(x/y)$ y lo definiremos como la función de distribución condicional de X , dado $Y=y$. Bajo las condiciones ya establecidas de continuidad absoluta de la función de distribución considerada, sabemos que existe una función no negativa que cumple

$$F_{x/y}(x/y) = \int_{-\infty}^x g(t) dt \quad , \quad \forall x \in \mathbb{R}.$$

a esta función y la designaremos como función de densidad de probabilidad condicional de X , dado $Y=y$, la denotaremos mediante $f_{x/y}(x/y)$. Es más que evidente que la función g verifica las condiciones que definen a una f.d.p.

Llegados a este punto cabe preguntarnos qué relación existe entre la f.d.p. condicionada y las f.d.p. conjuntas y marginales del vector (X, Y) . Veámoslo mediante el siguiente TEOREMA. - Sea f la f.d.p. conjunta del vector aleatorio continuo (X, Y) , y sea f_2 la marginal correspondiente de Y . Para cada punto de continuidad de f en el que además $f_2(y) > 0$ y es continua, se verifica

$$f_{x/y}(x/y) = \frac{f(x, y)}{f_2(y)}.$$

Demostración. - Revisemos que

$$\begin{aligned} F_{x/y}(x/y) &= \lim_{\varepsilon \rightarrow 0^+} \frac{P(X \leq x, Y-\varepsilon < Y \leq Y+\varepsilon)}{P(Y-\varepsilon < Y \leq Y+\varepsilon)} = \\ &= \lim_{\varepsilon \rightarrow 0^+} \frac{\int_{-\infty}^x \left\{ \int_{Y-\varepsilon}^{Y+\varepsilon} f(u, v) dv \right\} du}{\int_{Y-\varepsilon}^{Y+\varepsilon} f_2(v) dv} \end{aligned}$$

dividiendo numerador y denominador por 2ε , pasando al límite y teniendo en cuenta la relación que liga a las f.d.p. con las funciones de distribución en los puntos de continuidad de aquellas, tendremos:

$$F_{x/y}(x/y) = \frac{\int_{-\infty}^x f(u, y) du}{f_2(y)} = \int_{-\infty}^x \left\{ \frac{f(u, y)}{f_2(y)} \right\} du$$

si derivamos ahora, respecto de x , la función de distribución condicional, tendremos,

$$f_{\bar{z}/y}(x/y) = \frac{f(x,y)}{f_2(y)}$$

que es el resultado buscado.

Observación.- De la igualdad obtenida en el teorema

$$F_{\bar{z}/y}(x/y) = \frac{\int_{-\infty}^x f(u,y) du}{f_2(y)}$$

tenemos

$$f_2(y) \cdot F_{\bar{z}/y}(x/y) = \int_{-\infty}^x f(u,y) du$$

Si integramos para y en toda la recta real, tendríamos

$$\int_{-\infty}^{+\infty} \left[\int_{-\infty}^x f(u,y) du \right] dy = \int_{-\infty}^x \left[\int_{-\infty}^{+\infty} f(u,y) dy \right] du = \int_{-\infty}^x f_1(u) du = F_1(x)$$

que es la función de distribución marginal de $\bar{z}$, y en la otra parte del igual quedaría

$$F_1(x) = \int_{-\infty}^{+\infty} f_2(y) \cdot F_{\bar{z}/y}(x/y) dy.$$

Estas definiciones pueden trasladarse de forma inmediata al caso de un espacio m -dimensional.

De hecho, para $\bar{z} = (\bar{z}_1, \bar{z}_2)$, tendríamos

$$F_{\bar{z}/\bar{z}_2}(x_1/x_2) = \frac{\int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_m} f(x_1, \dots, x_m) dx_1 \dots dx_m}{f_{\bar{z}_2}(x_{k+1}, \dots, x_m)}$$

y para la función de densidad de probabilidad incondicional

$$f_{\bar{z}/\bar{z}_2}(x_1/x_2) = \frac{f(\bar{x})}{f_{\bar{z}_2}(\bar{x}_2)}, \text{ con } \bar{x} = (x_1, x_2).$$

Ejemplo 7.- Utilizando el vector bidimensional del ejemplo 5 (pag. 8), tendríamos

$$f_{\bar{z}/\bar{z}_2}(x_1/x_2) = \frac{f(x_1, x_2)}{f_2(x_2)} = \frac{2}{2x_2} = \frac{1}{x_2}, \quad 0 < x_1 < x_2$$

y decir, se trata de una distribución uniforme en el intervalo $0, x_2[$.

(13)

Análogamente

$$f_{\bar{z}_1/\bar{z}_2}(x_1/x_2) = \frac{f(x_1, x_2)}{f_1(x_1)} = \frac{2}{2(1-x_1)} = \frac{1}{1-x_1}, \quad x_1 < x_2 < 1$$

que es, nuevamente, una distribución uniforme en el intervalo $]x_1, 1[$. Para las funciones de distribución correspondientes

$$F_{\bar{z}_1/\bar{z}_2}(x_1/x_2) = \int_0^{x_1} f(t/x_2) dt = \int_0^{x_1} \frac{1}{1-x_2} dt = \frac{x_1}{1-x_2}, \quad 0 < x_1 < x_2$$

para $x_2 = \frac{2}{3}$, $x_1 = \frac{1}{3}$, tendríamos

$$F_{\bar{z}_1/\bar{z}_2}(1/3/2/3) = P(\bar{z}_1 \leq 1/3 / \bar{z}_2 = 2/3) = \frac{1/3}{1-2/3} = \frac{1}{2}.$$

Por otra parte

$$F_1(x_1) = \int_{-\infty}^{+\infty} f_2(x_2) \cdot F_{\bar{z}_1/\bar{z}_2}(x_1/x_2) dx_2 = \int_{x_1}^1 2x_2 \left[\frac{x_1}{x_2} \right] dx_2 = x_1 \int_{x_1}^1 2 dx_2 = x_1 [2x_2]_{x_1}^1 = 2x_1 - 2x_1^2, \quad 0 < x_1 < 1.$$

$$F_1(x_1) = 0, \quad x_1 \leq 0$$

$$F_1(x_1) = 1, \quad x_1 \geq 1.$$

como ya sabemos.

Truncamiento de una variable aleatoria

Heimos visto que si $\bar{z}$ es una variable aleatoria continua, mediante el cambio $Y = g(\bar{z})$ con $g(x) = x$, para $|x| < b$, $g(x) = -b$, $x \leq -b$ y $g(x) = b$, $x \geq b$, podemos llevar a cabo un truncamiento de la variable $\bar{z}$, pero existe el inconveniente de obtener una nueva variable, Y , que no es ni discreta, ni continua, por cuanto su función de distribución no es continua, ni tampoco es densidad. Haciendo uso de las probabilidades condicionadas podemos llevar a cabo un truncamiento de la variable que evite este inconveniente. Veamos como.

Definición.- Si $\bar{z}$ es una variable aleatoria ~~continua~~ sobre el espacio de probabilidad $(S, \mathcal{B}, P)$ y si T es un suceso de la recta real, tal que $0 < P(\bar{z} \in T) < 1$, entonces a la distribución incondicional $P(\bar{z} \in x / \bar{z} \in T)$, definida para cualquier x , se la llama distribución truncada de $\bar{z}$.

Obsérvese que la definición es válida para cualquier tipo de variable, así, para el caso de una variable discreta, la cosa ocurre de la siguiente manera:

$$P(\bar{z} = x_i / \bar{z} \in T) = \frac{P(\bar{z} = x_i, \bar{z} \in T)}{P(\bar{z} \in T)} = \begin{cases} \frac{f(x_i)}{\sum_{x_j \in T} f(x_j)}, & \text{si } x_i \in T \\ 0, & \text{en el caso contrario} \end{cases}$$

El caso más interesante, aquel en que X es continua, da lugar a

$$P(X \leq x / X \in T) = \frac{P(X \leq x, X \in T)}{P(X \in T)} = \frac{\int_{-\infty, 0 \cap T} f(t) \cdot dt}{\int_T f(t) \cdot dt}$$

La función de densidad de probabilidad para la variable truncada X

$$h(x) = \begin{cases} \frac{f(x)}{\int_T f(t) \cdot dt} & , x \in T \\ 0 & , x \in T^c \end{cases}$$

El efecto del truncamiento acumula sobre T toda la masa de probabilidad, por tanto

$$P(X \in T / X \in T) = 1.$$

Este es un método muy utilizado en teoría de la probabilidad y muy útil en particular cuando se estudian terrenos límites. Otra interesante aplicación del método de truncamiento de una variable continua cuando la variable original no tiene esperanza finita, pero de ello nos ocuparemos en el próximo capítulo.

Ejemplo 8. Sea X una v.a. $N(0,1)$ y sea $T =]-\infty, 0]$. Entonces $P(X \in T) = 1/2$ debido a

la simetría de X . Para la variable truncada tenemos pues

$$h(x) = \begin{cases} 2f(x) = \frac{1}{\sqrt{\pi}} \cdot e^{-\frac{1}{2}x^2} & , x \leq 0 \\ 0 & , \text{en otro caso.} \end{cases}$$

(15)

Algunos vectores aleatorios usuales.

(16)

Discretos

1. Distribución multinomial. Se trata de una generalización de la variable aleatoria binomial que en su momento estudiamos. Surge en situaciones como la siguiente:

Supongamos que llevamos a cabo n pruebas, independientes unas de otras, de tal manera que en cada una de ellas podemos tener como resultado uno de los r sucesos $E_1, E_2, \dots, E_r$, cada uno de los cuales teniendo una probabilidad p_i , $i=1, \dots, r$ de ocurrir, verificándose además $p_1 + p_2 + \dots + p_r = 1$. En estas condiciones la probabilidad de obtener, al final de las n pruebas, k_1 veces E_1 , k_2 veces E_2 , $\dots$, k_r veces E_r , con $k_1 + k_2 + \dots + k_r = n$ vendrá dada por:

$$\binom{n}{k_1} \binom{n-k_1}{k_2} \dots \binom{n-(k_1+k_2+\dots+k_{r-1})}{k_r} p_1^{k_1} \cdot p_2^{k_2} \cdot \dots \cdot p_r^{k_r}$$

que también puede escribirse

$$\frac{n!}{k_1! k_2! \dots k_r!} p_1^{k_1} \dots p_r^{k_r}.$$

Definamos ahora un vector aleatorio $\vec{X} = (X_1, \dots, X_r)$ donde X_i designa el número de veces que ocurre el suceso E_i . Para $\vec{x} \in A$, siendo $A = \{\vec{x} \in \mathbb{R}^r; x_i \geq 0, i=1, \dots, r, \sum_{i=1}^r x_i = n\}$, tendremos que la función de densidad vale

$$f(\vec{x}) = P(X_1 = x_1, \dots, X_r = x_r) = \frac{n!}{x_1! \dots x_r!} p_1^{x_1} \dots p_r^{x_r}$$

mientras que si $\vec{x} \in A^c$, entonces

$$f(\vec{x}) = 0$$

La función así definida es efectivamente una función de densidad, por cuanto es no negativa en $\mathbb{R}^r$ y además, al sumarla para todos los elementos de A , teniendo en cuenta el significado de los coeficientes multinomiales $\left(\frac{n!}{x_1! \dots x_r!}\right)$, tendremos

$$\sum_{\vec{x} \in A} f(\vec{x}) = \sum_{\vec{x} \in A} \frac{n!}{x_1! \dots x_r!} p_1^{x_1} \dots p_r^{x_r} = (p_1 + p_2 + \dots + p_r)^n = 1^n = 1.$$

Obtención de algunas marginales. Si queremos obtener la marginal de X_1 , procedemos así

$$f_1(x_1) = \sum_{\substack{\vec{x} \in A \\ x_2 = x_2}} f(\vec{x}) \quad \text{con } \vec{x}_2 = (x_2, \dots, x_r) \quad y \quad A_2 = \{\vec{x}_2; x_i \geq 0, i=2, \dots, r, \sum_{i=2}^r x_i = n - x_1\}$$

entonces

$$\begin{aligned} f_1(x_1) &= \sum_{\vec{x}_2 \in A_2} f(x_1, \vec{x}_2) = \sum_{\vec{x}_2 \in A_2} \binom{n}{x_1} \binom{n-x_1}{x_2} \dots \binom{x_r}{x_r} p_1^{x_1} \dots p_r^{x_r} = \\ &= \binom{n}{x_1} p_1^{x_1} \sum_{\vec{x}_2 \in A_2} \binom{n-x_1}{x_2} \binom{n-(x_1+x_2)}{x_3} \dots \binom{x_r}{x_r} p_2^{x_2} \dots p_r^{x_r} = \\ &= \binom{n}{x_1} p_1^{x_1} (p_2 + \dots + p_r)^{n-x_1} = \binom{n}{x_1} p_1^{x_1} (1-p_1)^{n-x_1} \end{aligned}$$

se trata pues de una binomial con parámetros n, p_1 . Obsérvese que razonando indistintamente sobre el significado de la marginal se llega al resultado encontrado.

Para marginales que involucren otra dimensión se obtienen análogamente multinomiales de dimensión coincidente con la del vector marginal considerado.

Para las distribuciones condicionales llegaremos a un resultado análogo.

2. Distribución binomial negativa en el caso bivalente. Supongamos que E_1, E_2, E_3 constituyen una partición del espacio muestral, de manera que $P(E_1) = p_1, P(E_2) = p_2, P(E_3) = p_3 = 1 - p_1 - p_2$. Realizemos un experimento cuyo resultado s necesariamente $E_1, E_2 \in E_3$, vamos a repetir este experimento, de manera independiente en cada ocasión, hasta que el suceso E_3 se haya realizado k veces, ello significa que E_1 habrá ocurrido x veces y E_2 habrá ocurrido y veces y todo ello antes de la k -ésima ocurrencia del suceso E_3 . la probabilidad de que la k -ésima ocurrencia sea E_3 , vendrá dada por

$$\binom{x+y+k-1}{x} \cdot \binom{y+k-1}{y} \cdot p_1^x \cdot p_2^y \cdot (1-p_1-p_2)^k = \frac{(x+y+k-1)!}{x! y! (k-1)!} p_1^x \cdot p_2^y \cdot (1-p_1-p_2)^k$$

Definamos ahora un vector aleatorio bidimensional (X, Y) donde $X \in \mathbb{N}$ denique el número de ocurrencias de los sucesos E_1, E_2 antes de la k -ésima ocurrencia del suceso E_3 . la función de densidad de este vector aleatorio vendrá dada por

$$f(x, y) = P(X=x, Y=y) = \frac{(x+y+k-1)!}{x! y! (k-1)!} p_1^x \cdot p_2^y \cdot (1-p_1-p_2)^k, \quad (x, y) \in A$$

donde $A = \{(x, y) \in \mathbb{R}^2; x = 0, 1, 2, \dots, y = 0, 1, 2, \dots\}$ y

$$f(x, y) = 0, \quad (x, y) \in A^c.$$

Se trata de una función de densidad por cuanto, $f(x, y) \geq 0, \forall (x, y) \in \mathbb{R}^2$, además, tenemos lo siguiente que

$$(1-p_1-p_2)^{-k} = \sum_{x, y \in A} \binom{x+y+k-1}{x} \binom{y+k-1}{y} p_1^x \cdot p_2^y$$

(17)

entonces

$$\sum_{(x, y) \in A} f(x, y) = (1-p_1-p_2)^k \cdot (1-p_1-p_2)^{-k} = 1.$$

Distribuciones marginales. la marginal de X , por ejemplo, la obtendríamos como sigue:

$$f_2(y) = \sum_{x \in A_1} f(x, y) \quad \text{donde } A_1 = \{x; x = 0, 1, 2, \dots\}$$

entonces

$$\begin{aligned} f_2(y) &= \sum_{x \geq 0} \binom{x+y+k-1}{x} \binom{y+k-1}{y} p_1^x p_2^y (1-p_1-p_2)^k = \\ &= \binom{y+k-1}{y} p_2^y (1-p_1-p_2)^k \sum_{x \geq 0} \binom{x+y+k-1}{x} p_1^x \end{aligned}$$

pero recordemos que $(1-x)^{-n} = \sum_{j \geq 0} \binom{n+j-1}{j} x^j$, por tanto

$$\begin{aligned} f_2(y) &= \binom{y+k-1}{y} p_2^y (1-p_1-p_2)^k (1-p_1)^{-(y+k)} = \binom{y+k-1}{y} \left(\frac{p_2}{1-p_1}\right)^y \cdot \left(\frac{1-p_1-p_2}{1-p_1}\right)^k = \\ &= \binom{y+k-1}{y} q_2^y (1-q_2)^k \quad \text{con } q_2 = \frac{p_2}{1-p_1}, \text{ siendo } 0 < q_2 < 1, y = 0, 1, \dots \end{aligned}$$

se trata pues de una binomial negativa con parámetros $k, y, q_2 = \frac{p_2}{1-p_1}$. Razonando de forma análoga llegaríamos a

$$f_1(x) = \binom{x+k-1}{x} q_1^x (1-q_1)^k, \quad \text{con } q_1 = \frac{p_1}{1-p_2}, \quad x = 0, 1, \dots$$

Distribuciones condicionales. Para X, Y , la variable aleatoria condicionada X/Y , tiene como función de densidad

$$\begin{aligned} f_{X/Y}(x/y) &= \frac{f(x, y)}{f_2(y)} = \frac{\binom{x+y+k-1}{x} \binom{y+k-1}{y} p_1^x p_2^y (1-p_1-p_2)^k}{\binom{y+k-1}{y} \left(\frac{p_2}{1-p_1}\right)^y \cdot \left(\frac{1-p_1-p_2}{1-p_1}\right)^k} = \\ &= \binom{x+y+k-1}{x} p_1^x (1-p_1)^{y+k}, \quad x = 0, 1, 2, \dots, y = 0, 1, \dots \end{aligned}$$

que es una binomial negativa con parámetros $y+k$ y p_1 .

(18)

Capítulo 7

Esperanza matemática o valor esperado

ESPERANZA MATEMÁTICA o VALOR ESPERADO

①

INTRODUCCIÓN

El concepto de esperanza aparece inicialmente, en Cálculo de Probabilidades, ligado a los juegos de azar y a las "estadísticas" de población. En el primer caso hacía referencia a la cantidad de dinero que un jugador debería obtener de su participación en determinado juego. En el otro caso el concepto "esperanza de vida", significaba la vida media de un individuo a la vez los datos considerados en la "estadística" en cuestión.

Volvamos al caso del jugador y supongamos que éste participa en el siguiente juego: Se lanza un dado, si la cara que presenta el dado es un número par el jugador recibe tantas pesetas como puntos indicia la cara, si por el contrario es impar el número de puntos el jugador deberá pagar dicha cantidad en pesetas. ¿Que ganancia o pérdida espera obtener el jugador en cada lanzamiento?

En el supuesto de un dado correcto si el jugador lleva a cabo un elevado número de lanzamientos, N , los distintos caras del dado deben aparecer, muy aproximadamente, el mismo número de veces, a saber, $N/6$. Así pues, en los N lanzamientos el jugador habrá ganado (o perdido) lo siguiente:

$$(-1) \cdot \frac{N}{6} + 2 \cdot \frac{N}{6} + (-3) \cdot \frac{N}{6} + 4 \cdot \frac{N}{6} + (-5) \cdot \frac{N}{6} + 6 \cdot \frac{N}{6}$$

por tanto en cada jugada debería obtener una cantidad E , que se obtendría de dividir por N la anterior, así pues

$$E = (-1) \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + (-3) \cdot \frac{1}{6} + 4 \cdot \frac{1}{6} + (-5) \cdot \frac{1}{6} + 6 \cdot \frac{1}{6} = \frac{1}{6} [2+4+6-(1+3+5)] = \frac{1}{6} (12-9) = \frac{3}{6} = 0.5$$

es decir, se gana 50 céntimos en cada jugada (de haber obtenido una cantidad negativa habría que interpretarlo como una pérdida).

Replanteemos ahora el problema de otra forma. Definamos una variable aleatoria X cuyos valores van a ser los pagos o las ganancias del jugador en cada jugada, de acuerdo con lo X tomará los siguientes valores (puntos ganados, negativos pagos)

$$X = \{-1, 2, -3, 4, -5, 6\}$$

así, teniendo en cuenta la naturaleza del experimento probabilístico asociado al juego, tendremos:

$$P(X=x_i) = \frac{1}{6}, \quad x_i = -1, 2, -3, 4, -5, 6$$

de acuerdo con lo, E podría también obtenerse mediante la siguiente expresión

②

$$E = \sum_{i=1}^6 x_i \cdot P(X=x_i) = \frac{1}{6} \left[\sum_{i=1}^6 x_i \right] = 0.5$$

a la expresión $\sum_{i=1}^6 x_i \cdot P(X=x_i)$ se la designa mediante $E(X)$ y se la denomina "esperanza de la variable aleatoria X ". Todavía cabe un nuevo replanteamiento de la cuestión. X , como variable aleatoria que es, supone una aplicación del espacio de probabilidad $(\Omega, \mathcal{A}, P)$ asociado al experimento de lanzar un dado y el espacio medible $(R, \mathcal{B})$, es decir, la recta real en su tribu de Borel, como tal aplicación, X puede ser escrita de la siguiente manera:

$$X = \sum_{i=1}^6 x_i \cdot \mathbf{1}_{A_i} \quad A_i = \{\omega \in \Omega; X(\omega) = x_i\} \quad x_i = -1, 2, -3, 4, -5, 6$$

es decir, se trata de una función simple. Recordemos que la integral de una función simple, siempre que fuera finita (o no negativa la función), se escribiría

$$\int_{\Omega} s \, dP = \sum_{i=1}^n a_i \cdot P(A_i) \quad \text{si} \quad s = \sum_{i=1}^n a_i \cdot \mathbf{1}_{A_i}$$

Aplicado a X , tendremos

$$\int_{\Omega} X \, dP = \sum_{i=1}^6 x_i \cdot P(A_i)$$

pero cada $A_i = \{\omega_i\}$, siendo ω_i el i -ésimo lanzamiento o puntos en la cara del dado y por tanto $P(A_i) = \frac{1}{6}$, $i=1, \dots, 6$, y en definitiva, teniendo en cuenta la definición de esperanza de la variable X que hemos dado, tendremos

$$E(X) = \int_{\Omega} X \, dP.$$

Esta última igualdad es la que se utiliza como definición del concepto de esperanza matemática de una variable aleatoria del tipo que ven. Definición que hemos visto su significado en el caso ~~discreto~~ discreto y que se adopta como tal para el caso continuo, pero haciendo algunas consideraciones de las que nos vamos a ocupar a continuación.

DEFINICIÓN. Sea X una variable aleatoria definida sobre el espacio de probabilidad $(\Omega, \mathcal{A}, P)$ en $(R, \mathcal{B}, P')$ (P' probabilidad inducida) se define la esperanza matemática de X , o el valor esperado de X , $E(X)$, mediante

$$E(X) = \int_{\Omega} X \, dP \quad \text{siempre que sea finita.}$$

Observación - A la luz de la definición de esperanza que hemos dado tiene sentido el hablar de la existencia o no de esta para una variable aleatoria, puesto que la definición viene condicionada por la finitud de la integral que en ella aparece.

Recordemos que si X es no negativa la integral

$$\int_{\Omega} X dP$$

está siempre definida, aunque puede no ser finita. Para el caso de X cualquiera ~~de integral~~ se dice ~~que X es integrable~~ que X es integrable, si es finita, una que omite cuando ~~ambos~~ X^+ y X^- tienen integral finita, en cuyo caso

$$\int_{\Omega} X dP = \int_{\Omega} X^+ dP - \int_{\Omega} X^- dP.$$

Si por otra parte recordamos la relación que existe entre los integrales sobre un mismo conjunto, de X y $|X|$, podemos afirmar que:

"la $E(X)$ existe si y solo si $E(|X|)$, que siempre está definida, es finita, es decir, existe".

La esperanza para v.a. discretas. Una v.a. discreta X , se caracteriza por la existencia de un conjunto $A \subset \mathbb{R}$, tal que $P(X \in A) = 1$, siendo a lo sumo, A , numerable. Esto nos permite escribir X de la siguiente forma

$$X = \sum_{a_i \in A} a_i P_{a_i} \quad . \quad A_i = \{\omega \in \Omega; X(\omega) = a_i\} \quad . \quad \cup A_i = \Omega \quad , \quad A_i \cap A_j = \emptyset, i \neq j$$

así pues, si existe

$$\begin{aligned} E(X) &= \int_{\Omega} X dP = \int_{\Omega} \left(\sum_{a_i \in A} a_i P_{a_i} \right) dP = \int_{\cup A_i} \left(\sum_{a_i \in A} a_i P_{a_i} \right) dP = \sum_{a_i \in A} \int_{A_i} a_i dP = \\ &= \sum_{a_i \in A} a_i \int_{A_i} dP = \sum_{a_i \in A} a_i \cdot P(A_i) = \sum_{a_i \in A} a_i \cdot P(X = a_i). \end{aligned}$$

La esperanza para v.a. continuas. En primer lugar recordemos, sin demostrar, un importante teorema que se aplica a los cambios de variable en una integral. Supongamos un espacio de medida $(\Omega, \mathcal{B}, \mu)$ y un espacio medible $(\Omega', \mathcal{B}')$ y entre ellos una aplicación T . Sea además f una función medible de $(\Omega', \mathcal{B}')$ en $(\mathbb{R}, \mathcal{B})$. Sobre $(\Omega', \mathcal{B}')$ introducimos una medida, μ' , mediante la aplicación medible T , como sigue

$$\mu'(A') = \mu(T^{-1}(A')).$$

Como podemos trasladar la integral de la función medible $f \circ T$ sobre Ω , a una integral sobre Ω' . El teorema que enunciaremos nos da la relación

TEOREMA I - Con los elementos anteriores y siempre que f sea no negativa o bien integrable, tenemos

$$\int_{\Omega} f \circ T d\mu = \int_{\Omega'} f d\mu'.$$

Este teorema tiene aplicación inmediata a nuestra situación. En efecto, hagamos $T \equiv X$, variable aleatoria del tipo continuo con la que vamos a trabajar, en esta situación $(\Omega', \mathcal{B}') \equiv (\mathbb{R}, \mathcal{B})$, $\mu \equiv P$ y $\mu' \equiv P'$, probabilidad inducida. Finalmente sea f la identidad. Tendremos pues que $f \circ T \equiv X$ y podremos escribir, si $E(X)$ existe

$$E(X) = \int_{\Omega} X dP = \int_{\mathbb{R}} x dP'$$

Por otra parte sabemos que la v.a. continua se caracteriza por la existencia de una función, la f.d.p. que permite escribir

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

siendo F la función de distribución, y también

$$P'(A) = \int_A f d\lambda$$

siendo $A \in \mathcal{B}$ y λ la medida de Lebesgue. A las medidas ~~asociadas~~ que gozan de esta propiedad (poseer una densidad respecto de otra medida; ~~este~~ ~~muchos~~ ~~casos~~ ~~de~~ ~~la~~ ~~densidad~~ ~~de~~ ~~P'~~ ~~respecto~~ ~~a~~ ~~la~~ ~~medida~~ ~~de~~ ~~Lebesgue~~) ~~podemos~~ ~~un~~ ~~cambio~~ ~~de~~ ~~medida~~, ~~aprovechando~~ ~~de~~ ~~aplicación~~ ~~al~~ ~~siguiente~~ ~~teorema~~, que también enunciaremos y no demostraremos

TEOREMA II - Si la medida ν tiene una densidad g respecto de la medida μ , entonces para toda función h , medible, no negativa o integrable, tenemos

$$\int_{\Omega} h d\nu = \int_{\Omega} h \cdot g d\mu.$$

Este teorema aplicado a nuestra situación coincide con $h \equiv x$, medible e integrable, $\nu \equiv P'$ y $\mu \equiv \lambda$, medida de Lebesgue y la densidad $g \equiv f$, en lugar a:

$$E(X) = \int_{\Omega} X dP = \int_{\mathbb{R}} x dP' = \int_{\mathbb{R}} x f(x) dx$$

por Teorema I por Teorema II

Finalmente si la función $x \cdot f(x)$ es integrable Riemann, como se dijo, el valor de su integral coincide con la integral de Lebesgue y obtenemos finalmente para la $E(X)$, siempre que exista

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx$$

Esperanza de una función de una variable aleatoria. Si transformamos una variable aleatoria X mediante una aplicación g medible, la nueva variable aleatoria $g(X)$ tiene una esperanza que se define como sigue:

Definición. Sea g una aplicación medible y X una variable aleatoria, si $E[|g(X)|] < +\infty$ definimos la esperanza de $g(X)$ mediante

$$E(g(X)) = \int_{\Omega} g(X) dP$$

sobre $(\Omega, \mathcal{F}, P)$ el espacio de probabilidad sobre el que está definida X .

Un razonamiento análogo al utilizado en los párrafos anteriores nos lleva a las siguientes expresiones de la $E(g(X))$, según que X sea discreta o continua.

X discreta:

$$E(g(X)) = \sum_{a_i \in A} g(a_i) \cdot P(X = a_i)$$

X continua:

$$E(g(X)) = \int_{\mathbb{R}} g(x) \cdot f(x) dx$$

y si $g(x) \cdot f(x)$ es tal que resulta ser integrable Riemann, entonces

$$E(g(X)) = \int_{\mathbb{R}} g(x) f(x) dx.$$

5 Momentos de una variable aleatoria

6

a) Momentos absolutos respecto del origen.

Si hacemos $g(X) = |X|^k$, entonces $E(g(X)) = E(|X|^k)$ que se denomina momento absoluto de orden k respecto del origen. Obsérvese que si el momento absoluto de orden k respecto del origen existe para una v.a. X , entonces para $j \leq k$, tendremos

$$|X|^j \leq 1 + |X|^k, \text{ y de aquí}$$

$$\int_{\mathbb{R}} |X|^j dP' \leq \int_{\mathbb{R}} (1 + |X|^k) dP' = 1 + E(|X|^k) < +\infty$$

y por tanto $E(|X|^j)$ también existe.

b) Momentos respecto del origen.

Si hacemos $g(X) = (X)^k$, entonces $E(g(X)) = E(X^k)$ que se denomina momento de orden k respecto del origen.

Obsérvese que para $k=1$, se obtiene la esperanza de la variable aleatoria como momento de orden uno respecto del ~~origen~~ origen.

c) Momentos respecto de una constante c .

Haciendo $g(X) = |X - c|^k$ o bien $g(X) = (X - c)^k$ se obtienen los momentos de orden k , absolutos o no, respecto de una constante c . Hay un caso especial de este tipo de momentos que es aquel para el cual $c = E(X)$, entonces a los momentos de este manera obtenidos se les denomina momentos centrales de orden k (absolutos o no). De entre los momentos centrales tiene especial interés el momento central de segundo orden, a saber

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

al que se le denomina varianza de la variable aleatoria.

A continuación nos vamos a ocupar de estudiar con detalle la esperanza y la varianza de una variable aleatoria a través de sus propiedades más relevantes.

Propiedades de la esperanza de una variable aleatoria

Hay una serie de propiedades que se derivan de inmediato de la definición de esperanza, son:

- 1) $E(c) = c$, donde c es una constante
- 2) $E[cg(X)] = cE[g(X)]$, en particular $E[cX] = cE[X]$.
- 3) $E[g(X) + d] = E[g(X)] + d$, d constante, en particular $E[X + d] = E[X] + d$

de la combinación de las dos últimas, llegamos a

4) $E[ag(X)+b] = a E[g(X)] + b$, con a, b constantes.

5) $E[\sum_{i=1}^n c_i g_i(X)] = \sum_{i=1}^n c_i E[g_i(X)]$, c_i constantes $i=1, \dots, n$.

6) Si $X \geq 0$, $E(X) \geq 0$.

7) De 6) se deriva $E(X) \geq E(Y)$ si $X \geq Y$, siendo ambas variables aleatorias.

Otras propiedades requieren una demostración explícita. Por ejemplo

Propiedad 8.- Sea X una v.a. no negativa con función de distribución F . Entonces

$$E(X) = \int_0^{\infty} (1-F(x)) dx,$$

en el sentido de que si alguno de los miembros de la igualdad existe también lo hace el otro y sus valores coinciden.

Demostración.- a) X es una v.a. continua.

Sabemos que la $E(X)$ cuando existe viene dada por

$$E(X) = \int_0^{\infty} x f(x) dx = \lim_{n \rightarrow \infty} \int_0^n x f(x) dx$$

Integrando por partes obtenemos

$$\int_0^n x f(x) dx = [x F(x)]_0^n - \int_0^n F(x) dx = n F(n) - \int_0^n F(x) dx$$

sumando y restando n , tenemos

$$\int_0^n x f(x) dx = -n + n F(n) + n - \int_0^n F(x) dx = -n [1-F(n)] + \int_0^n [1-F(x)] dx.$$

Pero

$$n [1-F(n)] = n \int_n^{\infty} f(x) dx < \int_n^{\infty} x f(x) dx$$

y puesto que $E(|X|) < \infty$, entonces

$$\lim_{n \rightarrow \infty} \int_n^{\infty} x f(x) dx = 0 \rightarrow \lim_{n \rightarrow \infty} n [1-F(n)] = 0,$$

tenemos por lo tanto

$$E(X) = \lim_{n \rightarrow \infty} \int_0^n x f(x) dx = \lim_{n \rightarrow \infty} \left[\int_0^n [1-F(x)] dx - n [1-F(n)] \right] = \int_0^{\infty} [1-F(x)] dx.$$

Por otra parte si suponemos de $\int_0^{\infty} [1-F(x)] dx < +\infty$, entonces

$$\int_0^n x f(x) dx \leq \int_0^n [1-F(x)] dx \leq \int_0^{\infty} [1-F(x)] dx, \forall n \text{ y de aquí } E(|X|) < +\infty.$$

(7)

b) X es una v.a. discreta

Sea $\{x_1, \dots, x_n, \dots\}$ el conjunto A tal que $P(X \in A) = 1$ y hagamos $P(X=x_j) = p_j$, entonces

$$E(X) = \sum_{j \geq 1} x_j p_j.$$

Sea $I = \int_0^{\infty} [1-F(x)] dx$. Entonces

$$I = \sum_{k \geq 1} \int_{(k-1)/n}^{k/n} P\{X > x\} dx$$

y puesto que $P(X > x)$ es una función no creciente de x , tendremos

$$P(X > \frac{k}{n}) \leq P(X > x) \leq P(X > \frac{k-1}{n}), \quad \frac{k}{n} \leq x \leq \frac{k-1}{n}, \quad \forall n$$

y de aquí, integrando y sumando sobre k ,

$$\frac{1}{n} \sum_{k \geq 1} P(X > \frac{k}{n}) \leq I \leq \frac{1}{n} \sum_{k \geq 1} P(X > \frac{k-1}{n}), \quad \forall n.$$

Hagamos

$$U_n = \frac{1}{n} \sum_{k \geq 1} P(X > \frac{k-1}{n}) \quad y \quad L_n = \frac{1}{n} \sum_{k \geq 1} P(X > \frac{k}{n}).$$

Tenemos

$$L_n = \frac{1}{n} \sum_{k \geq 1} \left[\sum_{j \geq k} P\left\{ \frac{j}{n} < X \leq \frac{j+1}{n} \right\} \right] = \frac{1}{n} \sum_{k \geq 2} (k-1) P\left\{ \frac{k-1}{n} < X \leq \frac{k}{n} \right\}$$

reordenando la serie. Así

$$L_n = \sum_{k \geq 2} \frac{k}{n} P\left\{ \frac{k-1}{n} < X \leq \frac{k}{n} \right\} - \sum_{k \geq 2} \frac{1}{n} P\left\{ \frac{k-1}{n} < X \leq \frac{k}{n} \right\} =$$

$$= \sum_{k \geq 2} \frac{k}{n} \left[\sum_{(k-1)/n < x_j \leq \frac{k}{n}} p_j \right] - \frac{1}{n} P\left\{ X > \frac{1}{n} \right\} \geq \sum_{k \geq 1} \left[\sum_{(k-1)/n < x_j \leq \frac{k}{n}} x_j p_j \right] - \frac{1}{n} =$$

$$= E(X) - \frac{1}{n}, \quad \forall n$$

Análogamente podemos demostrar que para cada n , tenemos

$$U_n \leq E(X) + \frac{1}{n}.$$

Tenemos por

$$E(X) - \frac{1}{n} \leq L_n \leq I \leq U_n \leq E(X) + \frac{1}{n}, \quad \forall n \text{ y así se demuestra.}$$

(8)

Una consecuencia de la propiedad 8 es esta misma propiedad.

Propiedad 9.- Para una v.a. cualquiera X , $E(|X|) < +\infty$ si y solo si las integrales

$\int_{-\infty}^0 P\{X \leq x\} dx$ y $\int_0^{\infty} P\{X > x\} dx$ son finitas, y además, en este caso

$$E(X) = \int_0^{\infty} P\{X > x\} dx - \int_{-\infty}^0 P\{X \leq x\} dx.$$

Demstración.- Si $E(|X|) < +\infty$, existe la esperanza de X y además sabemos que

$$E(X) = E(X^+) - E(X^-)$$

siendo

$$X^+ = \begin{cases} 0, & X < 0 \\ X, & X \geq 0 \end{cases} \quad X^- = \begin{cases} 0, & X > 0 \\ -X, & X \leq 0 \end{cases}$$

Setenta en ambos casos de variables aleatorias no negativas y podemos aplicarles la propiedad anterior. tendremos pues

$$E(X^+) = \int_0^{\infty} (1 - G(y)) dy = \int_0^{\infty} P\{X^+ > y\} dy, \text{ donde } G \text{ es la f.d. de } X^+$$

pero teniendo en cuenta la definición de X^+ , $P(X^+ > y) = P(X > y)$, $y \geq 0$, y por tanto

$$E(X^+) = \int_0^{\infty} P(X > x) dx.$$

Por otro parte

$$E(X^-) = \int_0^{\infty} (1 - H(y)) dy = \int_0^{\infty} P\{X^- > y\} dy, \text{ donde } H \text{ es la f.d. de } X^-$$

y teniendo en cuenta la definición de X^- tenemos, $P(X^- > y) = P(X < -y) = P(X \leq -y) - P(X = -y)$ y por tanto

$$E(X^-) = \int_0^{\infty} P(X \leq -x) dx - \int_0^{\infty} P(X = -x) dx = \int_{-\infty}^0 P(X \leq x) dx - \int_{-\infty}^0 P(X = x) dx$$


pero sea cual sea el tipo de v.a. de la que nos ocupemos la función $P(X=x)$ es distinta de cero a lo sumo en un conjunto numerable y por tanto su integral es cero. En definitiva

$$E(X) = \int_0^{\infty} P(X > x) dx - \int_{-\infty}^0 P(X \leq x) dx$$

(9)

La implicación contraria es derivada del hecho de ser $|X| = X^+ + X^-$ y (10) por tanto, si $E(X^+) < +\infty$ y $E(X^-) < +\infty$, entonces $E(|X|) = E(X^+) + E(X^-)$ y además es finita.

Comentario.- Obsérvese que la anterior expresión para la $E(X)$ tiene una interpretación geométrica



en función de las áreas que cubren las funciones $F(x)$ y $1-F(x)$ en los semiejes positivo y negativo respectivamente. Concretamente la diferencia entre las áreas (1) y (2) de la figura.

Propiedades de la varianza

1) $\sigma^2(c) = 0$, si c es una constante.

2) $\sigma^2(cg(X)) = c^2 \sigma^2(g(X))$. En particular $\sigma^2(cX) = c^2 \sigma^2(X)$

3) $\sigma^2(g(X) + d) = E\{[g(X) + d] - E[g(X) + d]\}^2 = E\{g(X) - E[g(X)] + d - E(d)\}^2 = E\{g(X) - E[g(X)] + d - d\}^2 = E\{g(X) - E[g(X)]\}^2 = \sigma^2(g(X))$.

Combinando 2 y 3 tenemos

4) $\sigma^2(cg(X) + d) = c^2 \sigma^2(g(X))$

5) $\sigma^2[g(X)] = E[g(X) - E(g(X))]^2 = E\{[g(X)]^2 - 2g(X) \cdot E(g(X)) + [E(g(X))]^2\} = E[g(X)]^2 - 2[E(g(X))]^2 + [E(g(X))]^2 = E[g(X)]^2 - [E(g(X))]^2$

lo que para una variable aleatoria se escribe

$$\sigma^2(X) = E[X^2] - [E(X)]^2.$$

TEOREMA.- Para una v.a. X , con $E|X|^2 < +\infty$, la $E[X - c]^2$ es mínima para $c = E(X)$, es decir, para la varianza.

Demstración.-

$$\begin{aligned} \sigma^2(X) &= E[X - E(X)]^2 = E\{X - c - [E(X) - c]\}^2 = E\{[X - c]^2 - 2(X - c)(E(X) - c) + [E(X) - c]^2\} \\ &= E[X - c]^2 - 2(E(X) - c)^2 + [E(X) - c]^2 = E[X - c]^2 - [E(X) - c]^2 \end{aligned}$$

y siendo $[E(X) - c]^2 \geq 0$, entonces $\sigma^2(X) \leq E[X - c]^2$, alcanzándose la igualdad para $c = E(X)$.

Tipificación de una v.a.

Una v.a. X se dice que está tipificada cuando $E(X) = 0$ y $\sigma^2(X) = 1$. Las propiedades anteriormente expuestas de la esperanza y de la varianza permiten obtener a partir de cualquier v.a. con $E(X) = \mu$ y $\sigma^2(X) = \sigma^2$, una nueva variable Y que está tipificada. En efecto, definamos

$$Y = \frac{X - E(X)}{\sqrt{\sigma^2(X)}} = \frac{X - \mu}{\sigma}$$

entonces

$$E(Y) = \frac{1}{\sigma} (E(X) - \mu) = 0$$

$$\sigma^2(Y) = \frac{1}{\sigma^2} \sigma^2(X - \mu) = \frac{1}{\sigma^2} \sigma^2(X) = 1.$$

Relación entre los momentos centrales y los momentos respecto del origen.

Los momentos respecto del origen se definen mediante

$$m_k = E(X^k)$$

mientras que los momentos centrales, μ_k

$$\mu_k = E(X - \mu)^k, \text{ donde } \mu = E(X).$$

Recordando el desarrollo del binomio de Newton (k entero positivo), tenemos

$$\begin{aligned} \mu_k &= E[(X - \mu)^k] = E\left[X^k - \binom{k}{1} X^{k-1} \mu + \binom{k}{2} X^{k-2} \mu^2 + \dots + (-1)^k \mu^k\right] = \\ &= m_k - \binom{k}{1} \mu \cdot m_{k-1} + \binom{k}{2} \mu^2 m_{k-2} + \dots + (-1)^k \mu^k \end{aligned}$$

Por otra parte

$$\begin{aligned} m_k &= E(X^k) = E[(X - \mu + \mu)^k] = E\left[(X - \mu)^k + \binom{k}{1} \mu (X - \mu)^{k-1} + \dots + \mu^k\right] = \\ &= \mu_k + \binom{k}{1} \mu \cdot \mu_{k-1} + \binom{k}{2} \mu^2 \mu_{k-2} + \dots + \mu^k. \end{aligned}$$

Estas relaciones nos permiten obtener unos u otros momentos conociendo los otros uno de ellos.

(11) ALGUNAS DESIGUALDADES DE INTERÉS

Se trata en este apartado de obtener algunas desigualdades para los momentos de una v.a. El principal resultado a obtener que demostraremos a continuación, que proporciona una cota superior para la cota de probabilidad extremas de algún momento de la v.a.

TEOREMA. - Sea $g(X)$ una función medible, no negativa de una v.a. X . Si existe $E[g(X)]$ entonces, para todo $\varepsilon > 0$, tenemos

$$P\{g(X) \geq \varepsilon\} \leq \frac{E[g(X)]}{\varepsilon}.$$

Demostración. - Recordemos que

$$E[g(X)] = \int_{\Omega} g(X) dP$$

tenemos también que todo integral de una función medible no negativa g una medida sobre la familia $\mathcal{A}$ de los conjuntos medibles. Sea

$$A = \{\omega \in \Omega; g(X(\omega)) \geq \varepsilon\}$$

$$A^c = \{\omega \in \Omega; g(X(\omega)) < \varepsilon\}.$$

Tendremos, $\Omega = A \cup A^c$, y de aquí

$$E[g(X)] = \int_{\Omega} g(X) dP = \int_{A \cup A^c} g(X) dP = \int_A g(X) dP + \int_{A^c} g(X) dP$$

pero como $g(X) \geq 0$, también $\int_A g(X) dP \geq 0$ y por tanto

$$E[g(X)] \geq \int_{A^c} g(X) dP \geq \varepsilon \int_{A^c} dP = \varepsilon \cdot P(A^c)$$

luego

$$P(A^c) = P\{g(X) \geq \varepsilon\} \leq \frac{E[g(X)]}{\varepsilon}.$$

COROLARIO I (Desigualdad de MARKOV). - Hagamos $g(X) = |X|^r$ y $\varepsilon = k^r$, con $r > 0, k > 0$.

Entonces

$$P\{|X|^r \geq k^r\} = P\{|X| \geq k\} \leq \frac{E[|X|^r]}{k^r}.$$

COROLARIO 2 (Desigualdad de Tchebychev) - Apoyándonos en la anterior desigualdad (13)

para $g(x) = |x - E(x)|^2 = |x - \mu|^2$, con $\mu = E(x)$ y para $E = k^2 \sigma^2(x) = k^2 \sigma^2$, con $\sigma^2 = \sigma^2(x)$, llegamos a la conocida desigualdad de Tchebychev

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

que en ocasiones, si tomamos $E = k^2$, también se nos presenta de la forma

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

Observación - Si x es una v.a. con $E(x) = \mu$ y $\sigma^2(x) = 0$, la desigualdad de Tchebychev nos conduce a

$$P(|x - \mu| \geq k) = 0, \quad \forall k > 0.$$

Sea $A_n = \{\omega: |x(\omega) - \mu| \geq \frac{1}{n}\}$, tendremos $P(A_n) = 0$. Además, por construcción $A_n \subset A_{n+1}$ por lo que $A_n^c \supset A_{n+1}^c$, siendo $P(A_n^c) = 1$. Si pasamos al límite tendremos

$$P(\cap A_n^c) = \lim_n P(A_n^c) = 1$$

pero $\cap A_n^c = \{\omega: |x(\omega) - \mu| < \frac{1}{n}, \forall n\} = \{\omega: |x(\omega) - \mu| = 0\} = \{\omega: x(\omega) = \mu\}$

y decir

$$P(x = \mu) = 1.$$

La v.a. es pues constante con probabilidad 1.

Este orden de cosas nos permite mejorar, en ocasiones, la desigualdad de Tchebychev si comprobamos la existencia de momentos de orden superior. Veamos a continuación, pero previamente necesitaremos el siguiente lema

LEMA - Sea x una v.a. con $E(x) = 0$ y $\sigma^2(x) = \sigma^2$. Entonces

$$P(x \geq x) \leq \frac{\sigma^2}{\sigma^2 + x^2}, \quad \text{si } x > 0$$

$$y \quad P(x > x) \geq \frac{x^2}{\sigma^2 + x^2}, \quad \text{si } x < 0.$$

Demostración - Sea $h(t) = (t+c)^2$, $c > 0$. Se trata de una función medible no negativa. Dado ω , para $0 < x < t$, tenemos $h(t) \geq (x+c)^2$. De aquí se sigue

$$P(x > x) \leq P\{h(x) \geq (x+c)^2\} \leq \frac{E(h(x))}{(x+c)^2}, \quad c > 0, x > 0.$$

Otro bien, como $E(x) = 0$, entonces $E(x^2) = \sigma^2$ y por tanto

$$P(x > x) \leq \frac{\sigma^2 + c^2}{(x+c)^2}, \quad c > 0, x > 0$$

pero $f(c) = \frac{\sigma^2 + c^2}{(x+c)^2}$ tiene un mínimo para $c = \sigma^2/x$ y portanto

$$P(x > x) \leq \frac{\sigma^2 + \sigma^4/x^2}{(x + \sigma^2/x)^2} = \frac{\sigma^2(x^2 + \sigma^2)}{(x^2 + \sigma^2)^2} = \frac{\sigma^2}{\sigma^2 + x^2}, \quad x > 0.$$

La otra desigualdad se demuestra de forma similar. Además, se puede demostrar que estas dos desigualdades no pueden mejorarse.

Con la ayuda del lema podemos ahora obtener una nueva desigualdad que mejora, en ocasiones, la desigualdad de Tchebychev.

TEOREMA - Sea x una v.a. tal que $E(|x|^4) < +\infty$, $E(x) = 0$ y $E(x^2) = \sigma^2$. Entonces

$$P\{|x| \geq k\sigma\} \leq \frac{\mu_4 - \sigma^4}{\mu_4 + \sigma^4 k^4 - 2k^2\sigma^4}, \quad \text{para } k > 1, \text{ donde } \mu_4 = E(x^4).$$

Demostración - En la primera de las desigualdades del lema anterior hagamos $x = (x^2 - \sigma^2)/(k^2 \sigma^2)$ y $x \neq 1$. Entonces

$$\begin{aligned} P\{x^2 - \sigma^2 \geq k^2 \sigma^2 - \sigma^2\} &\geq \frac{\sigma^2 \{ (x^2 - \sigma^2) / (k^2 \sigma^2 - \sigma^2) \}}{1 + \sigma^2 \{ (x^2 - \sigma^2) / (k^2 \sigma^2 - \sigma^2) \}} = \\ &= \frac{E\{[(x^2 - \sigma^2) - E(x^2 - \sigma^2)]^2\}}{\sigma^4 (k^2 - 1)^2 + E\{[(x^2 - \sigma^2) - E(x^2 - \sigma^2)]^2\}} = \frac{E\{(x^2 - \sigma^2)^2\}}{\sigma^4 (k^2 - 1)^2 + E\{(x^2 - \sigma^2)^2\}} = \\ &= \frac{\mu_4 - \sigma^4}{\sigma^4 (k^2 - 1)^2 + \mu_4 - \sigma^4} = \frac{\mu_4 - \sigma^4}{\mu_4 + \sigma^4 k^4 - 2k^2 \sigma^4}, \quad k > 1. \end{aligned}$$

Puede demostrarse que esta última es una mejora de la de Tchebychev si $k^2 \geq \mu_4/\sigma^4$ mientras que si $1 \leq k^2 < \mu_4/\sigma^4$ es peor que aquella.

Una propiedad que asegura la existencia de los momentos

Ya hemos visto que la existencia de la esperanza de una determinada función aleatoria $g(x)$ está vinculada a la existencia del correspondiente integral, es decir, a la integrabilidad de la función. El teorema que demostramos a continuación nos asegura la existencia de todos los momentos de una variable si ésta verifica ciertas condiciones:

TEOREMA.- Sea una v.a. X satisfaciendo

(15)

$$\frac{P\{|X| > \alpha k\}}{P\{|X| > k\}} \rightarrow 0, \text{ cuando } k \rightarrow \infty, \forall \alpha > 1.$$

Entonces X posee todos los momentos. (Obsérvese que si $\alpha = 1$, el límite es 1, mientras que si $\alpha < 1$, $P\{|X| > \alpha k\} \geq P\{|X| > k\}$ y el límite no puede ser 0).

Demostremos.- Sea $\varepsilon > 0$ (cuyo valor fijaremos más tarde), elegimos k_0 de manera que

$$\frac{P\{|X| > \alpha k\}}{P\{|X| > k\}} < \varepsilon, \quad \forall k \geq k_0.$$

Así mismo elegimos k_1 de manera que $P\{|X| > k\} < \varepsilon$, $\forall k \geq k_1$.

Sea $N = \max(k_0, k_1)$. Para cada entero r , fijo, tenemos

$$\frac{P\{|X| > \alpha^r k\}}{P\{|X| > k\}} = \prod_{p=1}^r \frac{P\{|X| > \alpha^p k\}}{P\{|X| > \alpha^{p-1} k\}}, \quad k \geq N$$

Como $k' = \alpha^{r-1} k > k \geq k_0$, tendremos que

$$\frac{P\{|X| > \alpha^p k\}}{P\{|X| > \alpha^{p-1} k\}} = \frac{P\{|X| > \alpha k'\}}{P\{|X| > k'\}} < \varepsilon, \quad p = 1, \dots, r$$

y por tanto

$$\frac{P\{|X| > \alpha^r k\}}{P\{|X| > k\}} < \varepsilon^r \rightarrow P\{|X| > \alpha^r k\} < \varepsilon^{r+1}, \quad k \geq N.$$

Por otra parte, como la variable aleatoria $|X|^n$ es no negativa, utilizando una propiedad antes demostrada tenemos

$$E[|X|^n] = \int_0^\infty [1 - F_{|X|^n}(y)] dy$$

que en términos de la f.d. de la v.a. $|X|$ y tras hacer el pertinente cambio de variable, adopta la forma:

$$E[|X|^n] = n \int_0^\infty x^{n-1} \cdot P\{|X| > x\} dx =$$

$$= n \int_0^N x^{n-1} \cdot P\{|X| > x\} dx + n \int_N^\infty x^{n-1} \cdot P\{|X| > x\} dx$$

(16)

puesto que la primera integral es finita, nos bastará demostrar la finitud de la segunda para comprobar la existencia de la $E(X^n)$, es decir

$$\begin{aligned} \int_N^\infty x^{n-1} \cdot P\{|X| > x\} dx &= \sum_{r=1}^\infty \int_{N^{r-1}N}^{N^rN} x^{n-1} \cdot P\{|X| > x\} dx \leq \\ &\leq \sum_{r=1}^\infty \left[(N^rN)^{n-1} \cdot P\{|X| > N^rN\} [N^rN - N^{r-1}N] \right] \leq \\ &\leq \sum_{r=1}^\infty (N^rN)^{n-1} \cdot \varepsilon^r \cdot 2N^rN = 2N^n \sum_{r=1}^\infty (\alpha^r \varepsilon)^r = \\ &= 2N^n \cdot \frac{\alpha^n \varepsilon}{1 - \alpha^n \varepsilon} < \infty \end{aligned}$$

siempre que ε haya sido adecuadamente elegido ($\varepsilon \alpha^n < 1$). Tenemos pues que $E(|X|^n) < \infty$, $\forall n$, y la función posee todos sus momentos.

MOMENTOS DE ALGUNAS VARIABLES ALEATORIAS

Caso discreto

1.- Bernoulli. Recordemos que se trata de una v.a. discreta que toma los valores 0 y 1 con probabilidad p y q respectivamente, de manera que $p + q = 1$.

$$E(X) = 0 \cdot p + 1 \cdot q = q$$

$$E(X^2) = 0^2 \cdot p + 1^2 \cdot q = q \quad \text{var}(X) = E(X^2) - [E(X)]^2 = q - q^2 = q(1-q) = q \cdot p.$$

2.- Binomial. Sea X una v.a. Binomial con parámetros n, p . Veamos cuál es su esperanza.

$$\begin{aligned} E(X) &= \sum_{x=0}^n x \cdot P(X=x) = \sum_{x=0}^n x \cdot \binom{n}{x} p^x \cdot q^{n-x} = \sum_{x=0}^n x \cdot \frac{n(n-1)\dots(n-x+1)}{x!} p^x \cdot q^{n-x} = \\ &= np \sum_{x=1}^n \frac{(n-1)\dots(n-x+1)}{(x-1)!} p^{x-1} \cdot q^{n-x} = np \sum_{x=1}^n \binom{n-1}{x-1} p^{x-1} \cdot q^{n-x} = np \end{aligned}$$

Para obtener la var(X), observemos que

$$E(X(X-1)) = E(X^2 - X) = E(X^2) - E(X)$$

Y de aquí

$$\text{var}(X) = E(X(X-1)) + E(X) - [E(X)]^2.$$

ahora bien

$$\begin{aligned} E(X(X-1)) &= \sum_{x=0}^n x(x-1) \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n x(x-1) \frac{n(n-1)\dots(n-x+1)}{x!} p^x q^{n-x} = \\ &= n(n-1)p^2 \sum_{x=2}^n \frac{(n-2)\dots(n-x+1)}{(x-2)!} p^{x-2} q^{n-x} = n(n-1)p^2 \sum_{x-2=0}^{n-2} \frac{(n-2)\dots(n-x+1)}{(x-2)!} p^{x-2} q^{n-x} = \\ &= n(n-1)p^2. \end{aligned}$$

Por tanto

$$\text{var}(X) = n(n-1)p^2 + np - n^2p^2 = np[(n-1)p + 1 - np] = np(1-p) = npq$$

Nota. Los momentos del tipo $E[X(X-1)\dots(X-n+1)]$ reciben el nombre de momentos factoriales de n -ésimo orden. Su utilidad les quedará de manifiesto en la obtención de la varianza anterior.

3.- Poisson. Si X es una v.a. Poisson con parámetro λ

$$E(X) = \sum_{x=0}^{\infty} x \cdot e^{-\lambda} \frac{\lambda^x}{x!} = e^{-\lambda} \sum_{x=1}^{\infty} \frac{\lambda^x}{(x-1)!} = \lambda \cdot e^{-\lambda} \sum_{x-1=0}^{\infty} \frac{\lambda^{x-1}}{(x-1)!} = \lambda \cdot e^{-\lambda} \cdot e^{\lambda} = \lambda.$$

$$E(X(X-1)) = \sum_{x=0}^{\infty} x(x-1) e^{-\lambda} \frac{\lambda^x}{x!} = \lambda^2 e^{-\lambda} \sum_{x=2}^{\infty} \frac{\lambda^{x-2}}{(x-2)!} = \lambda^2.$$

De aquí

$$\text{var}(X) = \lambda^2 + \lambda - \lambda^2 = \lambda.$$

Obsérvese que para una v.a. $P(\lambda)$, los momentos factoriales de orden n , valen λ^n . Efecto

$$E(X(X-1)\dots(X-n+1)) = \sum_{x=0}^{\infty} x(x-1)\dots(x-n+1) e^{-\lambda} \frac{\lambda^x}{x!} = \lambda^n e^{-\lambda} \sum_{x=n}^{\infty} \frac{\lambda^{x-n}}{(x-n)!} = \lambda^n.$$

Caso Continuo

1.- Uniforme. Sea X una v.a. uniforme en el intervalo $[a, b]$, entonces

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \int_a^b x \cdot \frac{1}{b-a} dx = \frac{1}{b-a} \int_a^b x dx = \frac{1}{b-a} \left[\frac{x^2}{2} \right]_a^b = \frac{1}{2}(a+b)$$

(17)

$$E(X^2) = \int_a^b x^2 \frac{1}{b-a} dx = \frac{1}{b-a} \left[\frac{x^3}{3} \right]_a^b = \frac{1}{3} \frac{b^3 - a^3}{b-a}$$

(18)

$$\begin{aligned} \text{var}(X) &= \frac{b^3 - a^3}{3(b-a)} - \left\{ \frac{1}{2}(a+b) \right\}^2 = \frac{1}{3} \cdot \frac{b^3 - a^3}{b-a} - \frac{1}{4} \cdot (b+a)^2 = \frac{4(b^3 - a^3) - 3(b^2 + a^2)ab}{12(b-a)}, \\ &= \frac{b^3 - 3b^2a + 3ba^2 - a^3}{12(b-a)} = \frac{(b-a)^3}{12(b-a)} = \frac{(b-a)^2}{12}. \end{aligned}$$

2.- Normal tipificada. Si X es una v.a. $N(0,1)$, entonces $E(X^{2n+1}) = 0$ y $E(X^{2n}) = \frac{(2n)!}{2^n (n!)}$, $n \geq 0$.

En efecto:

$$\begin{aligned} E(X^{2n+1}) &= \int_{-\infty}^{+\infty} x^{2n+1} f(x) dx = \int_{-\infty}^{+\infty} x^{2n+1} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^0 x^{2n+1} e^{-x^2/2} dx + \\ &+ \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx = -\frac{1}{\sqrt{2\pi}} \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx + \frac{1}{\sqrt{2\pi}} \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx = 0 \end{aligned}$$

Por otra parte

$$E(X^{2n}) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x^{2n} e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \cdot 2 \int_0^{+\infty} x^{2n} e^{-x^2/2} dx$$

ahora bien

$$\begin{aligned} \int_0^{+\infty} x^{2n} e^{-x^2/2} dx &= \int_0^{+\infty} (-x)^{2n-1} (-x) e^{-x^2/2} dx = \int_0^{+\infty} -x^{2n-1} d e^{-x^2/2} = \left[-x^{2n-1} \cdot e^{-x^2/2} \right]_0^{+\infty} + \\ &+ (2n-1) \int_0^{+\infty} x^{2n-2} e^{-x^2/2} dx = (2n-1) \int_0^{+\infty} x^{2n-2} e^{-x^2/2} dx \end{aligned}$$

Si designamos $E(X^{2n})$ por m_{2n} , tendremos

$$m_{2n} = (2n-1) m_{2n-2}$$

$$m_{2n-2} = (2n-3) m_{2n-4}$$

$$\dots \dots \dots$$

$$m_2 = 1 \cdot m_0$$

$$m_0 = 1, \text{ pues } m_0 = E(X^0) = E(1) = 1$$

Y de aquí

$$\text{var}(X) = E(X(X-1)) + E(X) - [E(X)]^2.$$

ahora bien

$$\begin{aligned} E(X(X-1)) &= \sum_{x=0}^n x(x-1) \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n x(x-1) \frac{n(n-1)\dots(n-x+1)}{x!} p^x q^{n-x} = \\ &= n(n-1)p^2 \sum_{x=2}^n \frac{(n-2)\dots(n-x+1)}{(x-2)!} p^{x-2} q^{n-x} = n(n-1)p^2 \sum_{x-2=0}^{n-2} \frac{(n-2)\dots(n-x+1)}{(x-2)!} p^{x-2} q^{n-x} = \\ &= n(n-1)p^2. \end{aligned}$$

Por tanto

$$\text{var}(X) = n(n-1)p^2 + np - n^2p^2 = np[(n-1)p + 1 - np] = np(1-p) = npq$$

Nota. Los momentos del tipo $E[X(X-1)\dots(X-n+1)]$ reciben el nombre de momentos factoriales de n -ésimo orden. Su utilidad les quedará de manifiesto en la obtención de la varianza anterior.

3.- Poisson. Si X es una v.a. Poisson con parámetro λ

$$E(X) = \sum_{x=0}^{\infty} x \cdot e^{-\lambda} \frac{\lambda^x}{x!} = e^{-\lambda} \sum_{x=1}^{\infty} \frac{\lambda^x}{(x-1)!} = \lambda \cdot e^{-\lambda} \sum_{x-1=0}^{\infty} \frac{\lambda^{x-1}}{(x-1)!} = \lambda \cdot e^{-\lambda} \cdot e^{\lambda} = \lambda.$$

$$E(X(X-1)) = \sum_{x=0}^{\infty} x(x-1) e^{-\lambda} \frac{\lambda^x}{x!} = \lambda^2 e^{-\lambda} \sum_{x=2}^{\infty} \frac{\lambda^{x-2}}{(x-2)!} = \lambda^2$$

De aquí

$$\text{var}(X) = \lambda^2 + \lambda - \lambda^2 = \lambda.$$

Obsérvese que para una v.a. $P(\lambda)$, los momentos factoriales de orden n , valen λ^n . Efecto

$$E(X(X-1)\dots(X-n+1)) = \sum_{x=0}^{\infty} x(x-1)\dots(x-n+1) e^{-\lambda} \frac{\lambda^x}{x!} = \lambda^n e^{-\lambda} \sum_{x=n}^{\infty} \frac{\lambda^{x-n}}{(x-n)!} = \lambda^n.$$

Caso Continuo

1.- Uniforme. Sea X una v.a. uniforme en el intervalo $[a, b]$, entonces

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \int_a^b x \cdot \frac{1}{b-a} dx = \frac{1}{b-a} \int_a^b x dx = \frac{1}{b-a} \left[\frac{x^2}{2} \right]_a^b = \frac{1}{2}(a+b)$$

(17)

$$E(X^2) = \int_a^b x^2 \frac{1}{b-a} dx = \frac{1}{b-a} \left[\frac{x^3}{3} \right]_a^b = \frac{1}{3} \frac{b^3 - a^3}{b-a}$$

(18)

$$\begin{aligned} \text{var}(X) &= \frac{b^3 - a^3}{3(b-a)} - \left\{ \frac{1}{2}(a+b) \right\}^2 = \frac{1}{3} \cdot \frac{b^3 - a^3}{b-a} - \frac{1}{4} \cdot (b+a)^2 = \frac{4(b^3 - a^3) - 3(b^2 + a^2)ab}{12(b-a)}, \\ &= \frac{b^3 - 3b^2a + 3ba^2 - a^3}{12(b-a)} = \frac{(b-a)^3}{12(b-a)} = \frac{(b-a)^2}{12}. \end{aligned}$$

2.- Normal tipificada. Si X es una v.a. $N(0,1)$, entonces $E(X^{2n+1}) = 0$ y $E(X^{2n}) = \frac{(2n)!}{2^n (n!)}$, $n \geq 0$.

En efecto:

$$\begin{aligned} E(X^{2n+1}) &= \int_{-\infty}^{+\infty} x^{2n+1} f(x) dx = \int_{-\infty}^{+\infty} x^{2n+1} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^0 x^{2n+1} e^{-x^2/2} dx + \\ &+ \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx = -\frac{1}{\sqrt{2\pi}} \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx + \frac{1}{\sqrt{2\pi}} \int_0^{+\infty} x^{2n+1} e^{-x^2/2} dx = 0 \end{aligned}$$

Por otra parte

$$E(X^{2n}) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x^{2n} e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \cdot 2 \int_0^{+\infty} x^{2n} e^{-x^2/2} dx$$

ahora bien

$$\begin{aligned} \int_0^{+\infty} x^{2n} e^{-x^2/2} dx &= \int_0^{+\infty} (-x)^{2n-1} (-x) e^{-x^2/2} dx = \int_0^{+\infty} -x^{2n-1} d e^{-x^2/2} = \left[-x^{2n-1} \cdot e^{-x^2/2} \right]_0^{+\infty} + \\ &+ (2n-1) \int_0^{+\infty} x^{2n-2} e^{-x^2/2} dx = (2n-1) \int_0^{+\infty} x^{2n-2} e^{-x^2/2} dx \end{aligned}$$

Si designamos $E(X^{2n})$ por m_{2n} , tendremos

$$m_{2n} = (2n-1) m_{2n-2}$$

$$m_{2n-2} = (2n-3) m_{2n-4}$$

$$\dots \dots \dots$$

$$m_2 = 1 \cdot m_0$$

$$m_0 = 1, \text{ pues } m_0 = E(X^0) = E(1) = 1$$

multiplicando ambos lados de las igualdades obtenemos:

$$m_{2n} = (2n-1)(2n-3) \dots 1 = \frac{2n(2n-1)(2n-2)(2n-3) \dots 2 \cdot 1}{2n(2n-2) \dots 2} =$$

$$= \frac{(2n)!}{2(n) \cdot 2(n-1) \dots 2 \cdot 1} = \frac{(2n)!}{2^n \cdot (n!)}$$

Entonces para la $E(X)$ y para la $var(X)$, tendremos

$$E(X) = 0$$

$$var(X) = E(X^2) = \frac{2!}{2! \cdot 1!} = \frac{2}{2} = 1.$$

Observación.- Si queremos obtener la Esperanza y la Varianza de una v.a. $N(\mu, \sigma^2)$, tendremos que al definir una nueva variable, a partir de esta, mediante

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

la variable Z resultará ser $N(0,1)$, por tanto

$$E(Z) = 0$$

pero

$$E(Z) = E\left[\frac{X - \mu}{\sigma}\right] = \frac{1}{\sigma} [E(X) - \mu] = 0 \rightarrow E(X) = \mu$$

además

$$var(Z) = 1 = var\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2} var(X) \rightarrow var(X) = \sigma^2$$

Así pues, la esperanza y la varianza de una $N(\mu, \sigma^2)$ coinciden con los parámetros de la distribución.

3.- Gamma. Sea X una v.a. Gamma con parámetros α y β .

$$E(X) = \int_0^{\infty} x f(x) dx = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x \cdot x^{\alpha-1} e^{-x/\beta} dx = \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^\alpha \cdot \frac{e^{-x/\beta}}{-\beta} dx =$$

$$= \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^\alpha d e^{-x/\beta} = \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \left[x^\alpha \cdot e^{-x/\beta} \right]_0^{\infty} - \alpha \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx =$$

$$= \frac{\alpha \beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx = \alpha \beta, \text{ pues } \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx = \Gamma(\alpha) \beta^\alpha$$

(19)

Análogamente

$$E(X^2) = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^{\alpha+1} \cdot e^{-x/\beta} dx = \beta^2 \alpha (\alpha+1).$$

Para la varianza

$$var(X) = E(X^2) - [E(X)]^2 = \beta^2 \alpha (\alpha+1) - \beta^2 \alpha^2 = \beta^2 \alpha.$$

Caso particular:

a) Si X es una χ_r^2 , tendremos que entonces $\alpha = r/2$, $\beta = 2$, con r entero, por tanto

$$E(X) = \frac{r}{2} \cdot 2 = r, \quad var(X) = \frac{r}{2} \cdot 4 = 2r$$

b) Si X es una exponencial negativa con parámetro λ , entonces $\alpha = 1$, $\beta = 1/\lambda$ y por tanto

$$E(X) = 1 \cdot \frac{1}{\lambda} = \frac{1}{\lambda}, \quad var(X) = 1 \cdot \frac{1}{\lambda^2} = \frac{1}{\lambda^2}.$$

4.- Cauchy. Esta situación es interesante por cuanto se trata de una variable que carece de momentos. En efecto

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \frac{\sigma}{\pi} \int_{-\infty}^{+\infty} \frac{x dx}{\sigma^2 + (x - \mu)^2}$$

podemos suponer $\mu = 0$, $\sigma = 1$, entonces

$$E(X) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x dx}{1+x^2} = \frac{1}{2\pi} [\log(1+x^2)]_{-\infty}^{+\infty} \text{ que es una indeterminación.}$$

De cualquier forma observe que

$$E(|X|) = \frac{1}{\pi} \int_{-\infty}^{+\infty} |x| \cdot \frac{dx}{1+x^2} = \frac{2}{\pi} \int_0^{\infty} \frac{x dx}{1+x^2} = \frac{1}{\pi} [\log(1+x^2)]_0^{+\infty} = +\infty$$

y por tanto no existe la esperanza.

Observación.- El valor principal de Cauchy para una integral impropia se define mediante

$$\lim_{b \rightarrow \infty} \int_{-b}^b g(x) dx$$

observe que en nuestro caso, el v.p.c. de la integral anterior es finito, naturalmente, aunque la integral no es convergente (pero luego en el caso de convergencia ambos valores coinciden).

(20)

multiplicando ambos lados de las igualdades tenemos:

$$m_{2n} = (2n-1)(2n-3) \dots 1 = \frac{2n(2n-1)(2n-2)(2n-3) \dots 2 \cdot 1}{2n(2n-2) \dots 2} =$$

$$= \frac{(2n)!}{2(n) \cdot 2(n-1) \dots 2 \cdot 1} = \frac{(2n)!}{2^n \cdot (n!)}$$

Entonces para la $E(X)$ y para la $var(X)$, tendremos

$$E(X) = 0$$

$$var(X) = E(X^2) = \frac{2!}{2! \cdot 1!} = \frac{2}{2} = 1.$$

Observación.- Si queremos obtener la Esperanza y la Varianza de una v.a. $N(\mu, \sigma^2)$, tendremos que al definir una nueva variable, a partir de esta, mediante

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

la variable Z resultará ser $N(0,1)$, por tanto

$$E(Z) = 0$$

pero

$$E(Z) = E\left[\frac{X - \mu}{\sigma}\right] = \frac{1}{\sigma} [E(X) - \mu] = 0 \rightarrow E(X) = \mu$$

además

$$var(Z) = 1 = var\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2} var(X) \rightarrow var(X) = \sigma^2$$

Así pues, la esperanza y la varianza de una $N(\mu, \sigma^2)$ coinciden con los parámetros de la distribución.

3.- Gamma. Sea X una v.a. Gamma con parámetros α y β .

$$E(X) = \int_0^{\infty} x f(x) dx = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x \cdot x^{\alpha-1} e^{-x/\beta} dx = \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^\alpha \cdot \frac{e^{-x/\beta}}{-\beta} dx =$$

$$= \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^\alpha d e^{-x/\beta} = \frac{-\beta}{\Gamma(\alpha) \beta^\alpha} \left[\int_0^{\infty} x^\alpha \cdot e^{-x/\beta} \right]_0^{\infty} - \alpha \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx \Big\} =$$

$$= \frac{\alpha \beta}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx = \alpha \beta \cdot \text{pus } \int_0^{\infty} x^{\alpha-1} \cdot e^{-x/\beta} dx = \Gamma(\alpha) \beta^\alpha$$

(19)

Análogamente

$$E(X^2) = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^{\infty} x^{\alpha+1} \cdot e^{-x/\beta} dx = \beta^2 \alpha (\alpha+1).$$

Para la varianza

$$var(X) = E(X^2) - [E(X)]^2 = \beta^2 \alpha (\alpha+1) - \beta^2 \alpha^2 = \beta^2 \alpha.$$

Caso particular:

a) Si X es una χ_r^2 , tendremos que entonces $\alpha = r/2$, $\beta = 2$, con renlento, por tanto

$$E(X) = \frac{r}{2} \cdot 2 = r, \quad var(X) = \frac{r}{2} \cdot 4 = 2r$$

b) Si X es una exponencial negativa con parámetro λ , entonces $\alpha = 1$, $\beta = 1/\lambda$ y por tanto

$$E(X) = 1 \cdot \frac{1}{\lambda} = \frac{1}{\lambda}, \quad var(X) = 1 \cdot \frac{1}{\lambda^2} = \frac{1}{\lambda^2}.$$

4.- Cauchy. Esta situación es interesante por cuanto se trata de una variable que carece de momentos. En efecto

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \frac{\sigma}{\pi} \int_{-\infty}^{+\infty} \frac{x dx}{\sigma^2 + (x - \mu)^2}$$

podemos suponer $\mu = 0$, $\sigma = 1$, entonces

$$E(X) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x dx}{1+x^2} = \frac{1}{2\pi} [\log(1+x^2)]_{-\infty}^{+\infty} \text{ que es una indeterminación.}$$

de cualquier forma observe que

$$E(|X|) = \frac{1}{\pi} \int_{-\infty}^{+\infty} |x| \cdot \frac{dx}{1+x^2} = \frac{2}{\pi} \int_0^{\infty} \frac{x dx}{1+x^2} = \frac{1}{\pi} [\log(1+x^2)]_0^{+\infty} = +\infty$$

y por tanto no existe la esperanza.

Observación.- El valor principal de Cauchy para una integral impropia se define mediante

$$\lim_{b \rightarrow +\infty} \int_{-b}^b g(x) dx$$

observe que en nuestro caso, el v.p.c. de la integral anterior es finito, inmediatamente, aunque la integral no es convergente (para luego en el caso de convergencia ambos valores coinciden).

(20)

OTRAS CARACTERISTICAS NUMERICAS DE UNA DISTRIBUCION DE PROBABILIDAD




El concepto de esperanza nos ha permitido obtener los momentos de diversos tipos de una distribución de probabilidad (concretamente de la v.a. correspondiente), que, en definitiva, no son más que características numéricas que nos permiten un conocimiento, sino exhaustivo, bastante aproximado y, en cualquier caso, de forma rápida de la distribución de probabilidad asociada a la v.a. Pero no son estas las únicas características numéricas de interés, a continuación introducimos otras, conocidas genéricamente como cuantiles.

Definición. Sea X una v.a. en f.d. F y sea p , tal que $0 < p < 1$. Toda cantidad x_p que satisficiera simultáneamente

$$P(X \leq x_p) = F(x_p) \geq p \quad \text{y} \quad P(X \geq x_p) \geq 1-p$$

se la denomina cuantil de orden p de la v.a. X (o de la distribución de probabilidad correspondiente).

Dadas la definición y las propiedades de la f.d. un cuantil de orden p existe siempre, pero no tiene porque ser único. En particular todas las soluciones de las ecuaciones antes planteadas son cuantiles de orden p , pudiendo ser número o no numerable; por ejemplo, si la recta $y=p$ y la f.d. $F(x)$ tienen un intervalo común, todo el intervalo está constituido por cuantiles del orden deseado. Por contra si la función de distribución es estrictamente creciente la solución es única y único el cuantil. Véase en las figuras algunos de los situaciones que pueden darse.



Algunos cuantiles tienen nombre propio. Si $p=0.1, 0.2, \dots, 0.9$ a los x_p correspondientes se les denomina deciles, si $p=0.25, 0.5, 0.75$ a los correspondientes x_p se les conoce como cuantiles de la distribución y de ellos tiene especial importancia la mediana, que es el segundo cuantil, es decir el correspondiente a $p=1/2$.

Como ocurre con todos los cuantiles la mediana no tiene porque ser única, pero si la distribución de probabilidad es simétrica, el centro de simetría de la misma coincide, desde luego, con la mediana. El papel de la mediana es importante, como medida de centralización, especialmente en aquellas v.a. que carecen de media, puesto que, como ya hemos advertido, nunca carece ni de mediana. Esta posee además otra importante propiedad:

(21) **Propiedad de la mediana.** Sea X una v.a. continua. El momento absoluto $E(|X-c|)$ alcanza (22) un mínimo si c es elige igual a la mediana de la distribución.

Demstración. Obtenemos en primer lugar que si X es una v.a. continua aún cuando la mediana no sea única, verifica las igualdades de las condiciones que la definen. Es decir, si m es una mediana, tenemos

$$F(m) = \frac{1}{2} \quad \text{y} \quad 1-F(m) = \frac{1}{2}.$$

Hecho esta observación, tenemos

$$\begin{aligned} E(|X-c|) &= \int_{-\infty}^{+\infty} |x-c| f(x) dx = \int_{-\infty}^c (c-x) f(x) dx + \int_c^{+\infty} (x-c) f(x) dx = \\ &= \int_{-\infty}^m (c-m+x) f(x) dx + \int_m^c (c-x) f(x) dx + \int_c^{+\infty} (x-m+m-c) f(x) dx = \\ &= \int_{-\infty}^m (m-x) f(x) dx + \int_c^{+\infty} (x-m) f(x) dx + \int_{-\infty}^m (c-m) f(x) dx + \int_m^c (c-x) f(x) dx + \\ &+ \int_c^{+\infty} (m-c) f(x) dx = E(|X-m|) - \int_m^c (x-m) f(x) dx + \int_m^c (c-x) f(x) dx + \\ &+ \int_{-\infty}^m (c-m) f(x) dx + \int_m^c (m-c) f(x) dx - \int_m^c (m-c) f(x) dx + \int_c^{+\infty} (m-c) f(x) dx = \\ &= E(|X-m|) + \int_{-\infty}^m (c-m) f(x) dx + \int_m^c (m-c) f(x) dx + \int_c^{+\infty} (c-x-x+m-m+c) f(x) dx = \\ &= E(|X-m|) + 2 \int_m^c (c-x) f(x) dx + (c-m) F(m) + (m-c) [1-F(m)] = \\ &= E(|X-m|) + 2 \int_m^c (c-x) f(x) dx \quad c > m \end{aligned}$$

Análogamente, para $m > c$, $E(|X-c|) = E(|X-m|) + 2 \int_c^m (x-c) f(x) dx$. En ambos casos el segundo sumando del segundo miembro c de la igualdad es positivo para $c \neq m$ y por tanto se verifica la propiedad enunciada.

Otra característica de interés es la MODA cuya definición damos a continuación.

Definición. Sea X una v.a. con función de densidad de probabilidad o de cuantía, f , según sea continua o discreta. Una moda de f , si existe, es cualquier número que maximiza $f(x)$.

De acuerdo con la definición, si f es diferenciable dos veces, la moda puede obtenerse mediante diferenciación de la función, todo se reduce a un problema clásico de máximos de una función. Sin embargo, esta actuación no es posible en el caso discreto. Para el caso de la Binomial y de la distribución de Poisson los dos tenemos que vienen a continuación modas la obtenemos independientemente.

TEOREMA (moda de la Binomial). Sea X una v.a. $B(n, p)$. Consideremos el número $(n+1)p$ y sea $[(n+1)p] = m$, la parte entera de $(n+1)p$. Entonces si $(n+1)p \neq [(n+1)p]$, $f(x)$ tiene una única moda para $x = m$. Si $(n+1)p = [(n+1)p]$, entonces las modas son dos, $x_1 = m$, $x_2 = m-1$.

Demostración. Tenemos

$$\frac{f(x)}{f(x-1)} = \frac{\binom{n}{x} p^x q^{n-x}}{\binom{n}{x-1} p^{x-1} q^{n-x+1}} = \frac{\frac{n!}{x!(n-x)!} p^x q^{n-x}}{\frac{n!}{(x-1)!(n-x+1)!} p^{x-1} q^{n-x+1}} = \frac{n-x+1}{x} \cdot \frac{p}{q}$$

por tanto $f(x) \geq f(x-1)$, creciente, si y solo si

$$(n-x+1)p \geq x(1-p), \text{ o bien } np - xp + p \geq x - xp, \text{ o bien } (n+1)p \geq x.$$

Así pues, si $(n+1)p$ no es entero, $f(x)$ aumenta para $x \leq [(n+1)p]$ y decrece a continuación. la moda será pues $m = [(n+1)p]$.

Si $(n+1)p$ es entero, entonces de los anteriores cálculos se deduce que para $x = (n+1)p$ $f(x) = f(x-1)$, luego en $x = (n+1)p - 1$ hay también una moda.

TEOREMA (moda de una v.a. Poisson). Sea X una v.a. $P(\lambda)$. Entonces si λ no es entero, $f(x)$ tiene una única moda en $x = [\lambda]$. Si λ es entero $f(x)$ tiene dos modas, en $x_1 = \lambda$, $x_2 = \lambda - 1$.

Demostración. Tenemos

$$\frac{f(x)}{f(x-1)} = \frac{e^{-\lambda} \cdot \lambda^x / x!}{e^{-\lambda} \cdot \lambda^{x-1} / (x-1)!} = \frac{\lambda}{x}$$

por tanto $f(x) \geq f(x-1)$ si y solo si $\lambda \geq x$. Así si λ no es entero la función aumenta mientras $x \leq [\lambda]$ y después disminuye. El máximo se alcanza en $x = [\lambda]$.

Si λ es entero, entonces para $x = \lambda$, $f(x) = f(x-1)$, luego el máximo se alcanza en $x = \lambda$ y en $x = \lambda - 1$.

Capítulo 8

Esperanza y momentos de un vector aleatorio

ESPERANZA Y MOMENTOS DE UN VECTOR ALEATORIO

DEFINICIÓN. Sea $(\Omega, \mathcal{A}, P)$ un espacio de probabilidad y $\vec{X}$ una aplicación medible de $(\Omega, \mathcal{A})$ en $(\mathbb{R}^m, \mathcal{B}^m)$, es decir, un vector aleatorio. Si g es una aplicación medible y g , definida de $\mathbb{R}^m$ en $\mathbb{R}$, también lo es, la composición $g(\vec{X})$ es una variable aleatoria, cuya esperanza se define de la forma consabida. A saber, si $g(\vec{X})$ es integrable, entonces

$$E(g(\vec{X})) = \int_{\Omega} g(\vec{X}) dP.$$

Ya sabemos que la anterior expresión tiene un significado en otro sentido en función del tipo de variable aleatoria que $g(\vec{X})$ es. Así, para el caso discreto, sabemos que

$$E(g(\vec{X})) = \sum_{\vec{x} \in A} g(\vec{x}) \cdot P(\vec{X} = \vec{x}) \quad \text{donde } A \text{ s.t. tal que } P(\vec{X} \in A) = 1.$$

Si nos situamos en el caso continuo

$$E(g(\vec{X})) = \int_{\mathbb{R}^m} g(\vec{x}) f(\vec{x}) d\vec{x} = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} g(x_1, \dots, x_m) f(x_1, \dots, x_m) dx_1 \dots dx_m$$

donde $f(\vec{x})$ es la función de densidad de probabilidad del vector aleatorio $\vec{X}$.

Los conceptos de momentos centrales ap. respecto del origen así como los momentos absolutos y los momentos no más tienen una definición paralela a la establecida para el caso de una variable aleatoria estudiada anteriormente con detalle. Surgen así subgrupos, entre otros, situándose nuevos de interés. En efecto:

a) Si $g(\vec{X}) = \vec{X}_1^{n_1} \dots \vec{X}_m^{n_m}$, con $n_i \geq 0$, entonces para $i=1, \dots, m$ a la correspondiente esperanza

$$E(g(\vec{X})) = E(\vec{X}_1^{n_1} \dots \vec{X}_m^{n_m})$$

si existe, se conoce como momento conjunto de orden $(n_1, \dots, n_m)$. Se suele denotar mediante $m_{n_1, \dots, n_m}$. Obsérvese que para $n_i = 1, n_j = 0, j \neq i$, tenemos el momento $m_{0, \dots, 1, \dots, 0}$ que coincide con la esperanza de la variable aleatoria $\vec{X}_i$ (no olvidemos que las componentes del vector aleatorio son todas variables aleatorias).

b) Análogamente, si $g(\vec{X}) = (\vec{X}_1 - E(\vec{X}_1))^{n_1} \dots (\vec{X}_m - E(\vec{X}_m))^{n_m}$, el momento resultante al obtener la esperanza es conocido como el momento central conjunto de orden $(n_1, \dots, n_m)$.

Los correspondientes momentos absolutos surgen de manera similar. Por un procedimiento interesante vamos a estudiar el caso bivariable.

VECTOR ALEATORIO BIDIMENSIONAL. - Para un vector aleatorio bidimensional (X, Y) , el momento central de orden $(1, 1)$ es conocido con el nombre de covarianza y su definición, cuando existe la correspondiente esperanza es

$$\begin{aligned} \text{cov}(X, Y) &= E((X - E(X))(Y - E(Y))) = E((X - m_{10})(Y - m_{01})) = E(XY) - E(X)E(Y) \\ &= m_{11} - m_{10} \cdot m_{01} \end{aligned}$$

Veamos a continuación una interesante propiedad

DESIGUALDAD DE CAUCHY-SCHWARZ. - Sean X e Y dos variables aleatorias con varianzas finitas. Entonces la $\text{cov}(X, Y)$ existe. Además,

$$[E(XY)]^2 \leq E(X^2) \cdot E(Y^2)$$

Verifíquese la igualdad si y sólo si existe un número real α tal que $P\{(\alpha X + Y) = 0\} = 1$.
Demostración. - Para cualquier par de números reales a, b tenemos

$$|ab| \leq \frac{a^2 + b^2}{2}$$

lo que significa que la $E(XY)$ ni $E(X^2) < +\infty$ y la $E(Y^2) < +\infty$. Por otra parte, para cualquier número real α , tenemos

$$E[(\alpha X + Y)^2] = \alpha^2 E(X^2) + 2\alpha E(XY) + E(Y^2)$$

Estándose de una función no negativa, $E[(\alpha X + Y)^2] \geq 0, \forall \alpha$, lo que impone que la ecuación de segundo grado de la derecha de la igualdad tiene a lo sumo una raíz y por tanto su discriminante será no positivo, es decir

$$[E(XY)]^2 \leq E(X^2) \cdot E(Y^2).$$

Obsérvese que ni $[E(XY)]^2 = E(X^2) \cdot E(Y^2)$ la ecuación tiene raíz doble, es decir $\alpha = -\frac{E(XY)}{E(X^2)}$, lo que antitendido en la ecuación supone que $E[(\alpha X + Y)^2] = 0$ y dado, las características de la función $(\alpha X + Y)^2$ y las propiedades de la integral de una función no negativa tendremos $P\{(\alpha X + Y) = 0\} = 1$.

Introducido el concepto de covarianza podemos ahora conocer el valor de la variancia de una suma finita de variables aleatorias.

VARIANZA DE UNA SUMA. - Sean $X_1, \dots, X_n$ variables aleatorias cuyas varianzas existen. Sean $a_1, \dots, a_n$ números reales. Definimos

$$S = \sum_{i=1}^n a_i X_i.$$

Entonces la variancia de S existe y viene dada por

$$\text{var}(S) = \sum_{i=1}^n a_i^2 \text{var}(X_i) + \sum_{i=1}^n \sum_{j=1, j \neq i}^n a_i a_j \text{cov}(X_i, X_j).$$

En particular si las variables aleatorias son tales que todas las posibles covarianzas son nulas, entonces

$$\text{var}(S) = \sum_{i=1}^n a_i^2 \text{var}(X_i).$$

Demostración.- El resultado se sigue de desarrollar el cuadrado

$$\left[\sum_{i=1}^n a_i x_i - \sum_{i=1}^n a_i \bar{x}_i \right]^2$$

y después tomar esperanza.

ALGUNAS DESIGUALDADES DE INTERÉS

Lema.- Para a, b reales no negativos, tenemos

$$|a+b|^r \leq G_r (|a|^r + |b|^r), \text{ donde } G_r = 1, \text{ si } 0 \leq r \leq 1 \text{ y } G_r = 2^{r-1} \text{ si } r \geq 1.$$

Demostración.- Para $r=0$ y $r=1$ la desigualdad es trivialmente cierta. Observemos por otra parte que basta comprobar la desigualdad para $0 < a \leq b$. Así pues, $0 < a \leq b$, hagamos $x = a/b$. Entonces

$$\frac{(a+b)^r}{a^r + b^r} = \frac{(1+x)^r}{1+x^r}$$

Sea $f(x) = (1+x)^r / (1+x^r)$, la derivada vale

$$f'(x) = \frac{r(1+x)^{r-1}}{(1+x^r)^2} (1-x^{r-1}), \quad 0 < x \leq 1, r > 0.$$

Se sigue que $f'(x) > 0$, si $r > 1$, para $r=1$, entonces $f'(x) = 0$ y para $r < 1$, entonces $f'(x) < 0$. De consecuencia

$$\max_{0 \leq x \leq 1} f(x) = f(0) = 1, \quad \text{si } r \leq 1$$

$$\max_{0 \leq x \leq 1} f(x) = f(1) = 2^{r-1}, \quad \text{si } r \geq 1.$$

Con lo que queda demostrado el lema.

Obsérvese que habíamos podido obtener, de inmediato, una cota del tipo

$$|a+b|^r \leq 2^r (|a|^r + |b|^r)$$

puesto que

$$|a+b| \leq \max(2|a|, 2|b|)$$

y de aquí al pasar a la r -ésima potencia obtenemos la desigualdad anterior.

Como una aplicación de esta desigualdad obtenida en el lema tenemos la siguiente propiedad.

Teorema.- Sean X y Y variables aleatorias y $r > 0$ un número fijo. Si $E(|X|^r)$ y $E(|Y|^r)$ son ambos finitos, entonces también lo es $E(|X+Y|^r)$.

Demostración.- Basta tomar $a=X$, $b=Y$ y aplicar la desigualdad anterior, luego tomamos esperanzas y llegamos al resultado enunciado en el teorema.

③ DESIGUALDAD DE HÖLDER.- Para x y y reales cualesquiera y para p, q , dos números reales positivos tales que $p > 1$ y $1/p + 1/q = 1$, tenemos

$$|xy| \leq \frac{|x|^p}{p} + \frac{|y|^q}{q}$$

Demostración.- Observemos que para $x > 0$, la función $w = \log x$ es concava, por tanto para $0 < t < 1$ y para $x_1 > 0, x_2 > 0$, tenemos

$$\log [tx_1 + (1-t)x_2] \geq t \log x_1 + (1-t) \log x_2.$$

Tomando antilogaritmos, tenemos

$$x_1^t \cdot x_2^{(1-t)} \leq tx_1 + (1-t)x_2.$$

Elijamos ahora $x_1 = |x|^p$, $x_2 = |y|^q$, $t = 1/p$, $1-t = 1/q$, con $p > 1$ y $1/p + 1/q = 1$, llegando entonces a

$$|xy| \leq \frac{|x|^p}{p} + \frac{|y|^q}{q}$$

desigualdad conocida como la desigualdad de Hölder.

Aplicando la desigualdad de Hölder obtenemos otra conocida desigualdad en términos de

DESIGUALDAD DE MINKOWSKI.- Para $p \geq 1$

$$\{E[|X+Y|^p]\}^{1/p} \leq \{E[|X|^p]\}^{1/p} + \{E[|Y|^p]\}^{1/p}$$

Demostración.- El caso $p=1$ surge como caso inmediato del hecho $|X+Y| \leq |X| + |Y|$.

Sea $p > 1$, tenemos

$$|X+Y|^p = |X+Y| \cdot |X+Y|^{p-1} \leq |X+Y| \cdot (|X| + |Y|)^{p-1}$$

tomando esperanzas y utilizando la desigualdad de

esperanzas que, a su vez, puede considerarse también como la desigualdad de Hölder.

DESIGUALDAD DE HÖLDER PARA ESPERANZAS.- Sean $p > 1, q > 1$ tales que $1/p + 1/q = 1$.

Entonces

$$E(|XY|) \leq \{E(|X|^p)\}^{1/p} \{E(|Y|^q)\}^{1/q}.$$

Demostración.- Utilizando la desigualdad de Hölder, con $x = |X|^p$ y $y = |Y|^q$, llegamos a

$$|XY| \leq p^{-1} |X|^p \{E(|X|^p)\}^{1/p-1} \{E(|Y|^q)\}^{1/q} + q^{-1} |Y|^q \{E(|Y|^q)\}^{1/q-1} \{E(|X|^p)\}^{1/p}$$

tomando esperanzas llegamos a la desigualdad buscada.

Un resultado importante de su última desigualdad nos conduce a la ya conocida (5) desigualdad de Cauchy-Schwarz. En efecto, para $p=q=2$, tenemos

$$E(|XY|) \leq \{E(X^2)\}^{1/2} \cdot \{E(Y^2)\}^{1/2},$$

que puede también escribirse bajo la forma más conocida

$$\{E(XY)\}^2 \leq E(X^2) \cdot E(Y^2).$$

Finalicemos con una desigualdad atribuida a Minkowski.

DESIGUALDAD DE MINKOWSKI. - Para $p \geq 1$,

$$\{E(|X+Y|^p)\}^{1/p} \leq \{E(|X|^p)\}^{1/p} + \{E(|Y|^p)\}^{1/p}.$$

Demostración. - Para $p=1$, la desigualdad es consecuencia inmediata de $|X+Y| \leq |X| + |Y|$.

Sea $p > 1$, entonces

$$|X+Y|^p = |X+Y| \cdot |X+Y|^{p-1} \leq |X| \cdot |X+Y|^{p-1} + |Y| \cdot |X+Y|^{p-1}$$

tomando esperanzas y utilizando la desigualdad de Hölder, en la que tenemos $q = (p-1)q = p$, tenemos

$$\begin{aligned} E(|X+Y|^p) &\leq \{E(|X|^p)\}^{1/p} \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q} + \{E(|Y|^p)\}^{1/p} \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q} \\ &= [\{E(|X|^p)\}^{1/p} + \{E(|Y|^p)\}^{1/p}] \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q}. \end{aligned}$$

Excluyendo el caso trivial en que $E(|X+Y|^p) = 0$ y teniendo en cuenta que $(p-1)q = p$, reemplazando adecuadamente en la anterior desigualdad llegamos al resultado buscado.

ESPERANZA CONDICIONADA

Recordemos que si $\vec{X}$ es un vector aleatorio al que haremos en dos subvectores $\vec{X}_1, \vec{X}_2$, para $\vec{X}_1 = \vec{x}_1$ tal que $f_{\vec{X}_1}(\vec{x}_1) > 0$, la función

$$f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2) = \frac{f(\vec{x})}{f_{\vec{X}_1}(\vec{x}_1)}, \text{ con } \vec{x} = (\vec{x}_1, \vec{x}_2) \text{ y } f \text{ la f.d.p. conjunta}$$

define una f.d.p.; más convenientemente define una distribución de probabilidad para el subvector $\vec{X}_2$ condicionada a que el otro subvector $\vec{X}_1$ tome un valor fijo $\vec{x}_1$.

Tendrán pues sentido estudiar la esperanza de este subvector condicionando, utilizando para ello la correspondiente f.d.p. La definición usual y establecida para el concepto de esperanza. Por motivos de simplicidad vamos a considerar el caso de un vector bidimensional en el que los subvectores sean cada uno de los miembros que lo componen, la generalización a dimensiones mayores es inmediata.

DEFINICIÓN. - Sea $\vec{X} = (X, Y)$ un vector aleatorio definido sobre el espacio de probabilidad $(\Omega, \mathcal{A}, P)$ y sea h una función medible definida de $\mathbb{R}$ en $\mathbb{R}$. Supongamos que existe la $E(h(\vec{X}))$. Entendemos la esperanza condicionada de $h(X)$, dado Y , que se escribe $E(h(X)/Y)$, es una variable aleatoria que toma el valor $E(h(X)/y)$, definido mediante

$$E(h(X)/Y) = \int_{\Omega} h(x) dP_{Y=y}$$

donde $P_{Y=y}$ quiere significar la distribución de probabilidad condicionada a que Y tome el valor y . Según el tipo de vector aleatorio que sea $\vec{X} = (X, Y)$ aquí la expresión adopta la forma:

$$1) \quad E(h(X)/Y) = \int_{x \in A} h(x) \cdot P(X=x/Y=y) = \int_{x \in A} h(x) \cdot \frac{f(x,y)}{f_2(y)}$$

donde $A = B_y$, la imagen de B mediante Y , siendo B tal que $P(\vec{X} \in B) = 1$.

Esto para el caso en que $\vec{X}$ sea un vector aleatorio de tipo discreto.

2) En el caso continuo

$$E(h(X)/Y) = \int_{\mathbb{R}} h(x) \cdot f_{X/Y}(x) dx = \int_{\mathbb{R}} h(x) \cdot \frac{f(x,y)}{f_2(y)} dx$$

Observese que en ambos casos $E(h(X)/Y)$ es, efectivamente, una función del valor Y .

Obramente, una definici3n mltar puda darse para $E(h(x)/y)$, siempre que $E(h(x))$.

Dada la definici3n establecida 3 evidente que la esperanza condici3nada goza de las propiedades inherentes al concepto de esperanza y que ya hemos estudiado. Recordemos a ttulo de ejemplo:

PROPIEDADES DE LA ESPERANZA CONDICIONADA

- $E(c/y) = c$, donde c 3 constante.
- $E(aX + b/y) = aE(X/y) + b$, a, b constantes.
- Si h_1 y h_2 son funciones medibles, de manera que sus esperanzas, $E(h_i(x))$ existan, tenemos

$$E\{[a_1 h_1(x) + a_2 h_2(x)]/y\} = a_1 E(h_1(x)/y) + a_2 E(h_2(x)/y).$$
- Si $X \geq 0$, entonces $E(X/y) \geq 0$.
- Si $X_1 \geq X_2$, entonces $E(X_1/y) \geq E(X_2/y)$.

Momentos de todo tipo de una distribuci3n de probabilidad condicional se definen de forma an3loga a como se establecieron en un principio y, quien tambi3n, claro est3, de las mismas propiedades. Sin embargo, las caractersticas especiales de este tipo de distribuciones son lugar a algunas propiedades que las caracteriz3n. Recordemos.

PROPIEDAD 1 - Si $E(h(x))$ existe, entonces

$$E[E(h(x)/y)] = E(h(x)).$$

Demstraci3n - Si $\vec{x}$ 3 un vector aleatorio continuo, entonces la v.a. $E(h(x)/y)$ viene definida mediante

$$g(y) = E(h(x)/y) = \int_{\mathbb{R}} h(x) \frac{f(x,y)}{f_2(y)} dx$$

como funci3n medible de la variable aleatoria Y que 3, en s3 misma medida, dada por

$$\begin{aligned} E[g(Y)] &= \int_{\mathbb{R}} g(y) \cdot f_2(y) dy = \int_{\mathbb{R}} \left[\int_{\mathbb{R}} h(x) \frac{f(x,y)}{f_2(y)} dx \right] f_2(y) dy = \\ &= \int_{\mathbb{R}} \left[\int_{\mathbb{R}} h(x) f(x,y) dx \right] dy = \int_{\mathbb{R}} h(x) \left[\int_{\mathbb{R}} f(x,y) dy \right] dx = \\ &= \int_{\mathbb{R}} h(x) f_1(x) dx = E(h(x)). \end{aligned}$$

Para el caso discreto la demostraci3n 3 an3loga.

PROPIEDAD 2 - Si $E(x^2) < +\infty$, entonces

$$\text{var}(X) = \text{var}(E(X/y)) + E(\text{var}(X/y)).$$

Demstraci3n - Haci3ndo uso de la propiedad anterior, notamos que

$$\begin{aligned} \text{var}(X) &= E((X - E(X))^2) = E[E((X - E(X))^2/y)] = E[E\{X^2 + (E(X))^2 - 2XE(X)\}/y)] = \\ &= E[E(X^2/y) + (E(X))^2 - 2E(X) \cdot E(X/y)] = E[E(X^2/y) - (E(X/y))^2 + (E(X/y))^2 + \\ &\quad + (E(X))^2 - 2E(X) \cdot E(X/y)] = E[\text{var}(X/y) + (E(X/y) - E(X))^2] = \\ &= E(\text{var}(X/y)) + E[(E(X/y) - E(X))^2] = E(\text{var}(X/y)) + \text{var}(E(X/y)). \end{aligned}$$

COROLARIO - Si $E(X^2) < +\infty$, entonces de la propiedad 2 se sigue de inmediato que

$$\text{var}(X) \geq \text{var}(E(X/y)).$$

Obt3nase por otra parte que cuando se verifica la igualdad $\text{var}(X) = \text{var}(E(X/y))$, ello supone que

$$E(\text{var}(X/y)) = 0$$

3 decir

$$E((X - E(X/y))^2/y) = 0$$

y de acuerdo con las propiedades de las integrales de funciones medibles no negativas, ello supone que la funci3n $(X - E(X/y))^2$

3 nula casi por todas partes, o sea

$$P(X = E(X/y)) = 1$$

lo que supone que X 3, casi por todas partes, una funci3n de Y , por cuanto $E(X/y)$ lo 3.

EL PRINCIPIO DE LOS MÍNIMOS CUADRADOS

(9)

Sean X e Y dos variables aleatorias de manera que existe entre ellas una relación de dependencia que debemos determinar. Supongamos que la relación funcional entre ambas, ~~es una función~~ ~~que~~ $E(Y^2)$ y $E[h(X)^2]$ son finitas, vamos a buscar de minimizar una función $h(x)$ que aproxime el valor de la relación funcional entre X e Y .

El principio de los mínimos cuadrados consiste en la elección de $h(x)$ de tal suerte que la cantidad

$$E\{Y - h(X)\}^2$$

sea mínima. ¿cómo ha de ser entonces $h(x)$?

Observemos que, si (X, Y) es un vector aleatorio continuo, tenemos

$$\begin{aligned} E\{Y - h(X)\}^2 &= \int_{\mathbb{R}^2} [Y - h(x)]^2 f(x, y) dx dy = \int_{\mathbb{R}^2} [Y - h(x)]^2 f_{Y/X}(y) f_X(x) dy dx = \\ &= \int_{\mathbb{R}} f_X(x) \left\{ \int_{\mathbb{R}} [Y - h(x)]^2 f_{Y/X}(y) dy \right\} dx, \end{aligned}$$

que sea mínima esta expresión supone que se minimiza lo que figura entre llaves en el integrando y de acuerdo con las propiedades estudiadas para la variancia, dicha cantidad se minimiza si cuando $h(x) = E(Y/X)$.

Un resultado análogo se verifica por el caso en que (X, Y) es discreto.

DEFINICIÓN - la relación $Y = E(Y/X)$ se conoce como la regresión de Y sobre X , análogamente $X = E(X/Y)$ es la regresión de X sobre Y .

LÍNEA DE REGRESIÓN - En realidad, por motivos de sencillez fundamentalmente, resulta interesante en aproximar la relación entre X e Y mediante una línea recta, $Y = aX + b$. En esta situación y haciendo uso del principio de los mínimos cuadrados antes citado, a a y b se les da de la siguiente manera que

$$L = E\{Y - aX - b\}^2$$

sea mínimo. Siempre bajo el supuesto de la existencia de $E(X^2)$ y $E(Y^2)$, la elección de a y b se reduce a un problema de máximos y mínimos, buscando en derivar parcialmente L respecto a ambos parámetros e igualar, posteriormente, a cero dichas derivadas. Se obtienen así para a y b , las expresiones

$$a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}, \quad b = E(Y) - E(X) \cdot \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

haciendo la ecuación de la recta, conocida como línea de regresión de Y sobre X ,

$$Y - E(Y) = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} (X - E(X)). \quad (1)$$

Una expresión análoga se obtiene para la línea de regresión de X sobre Y , a saber (10)

$$X - E(X) = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} (Y - E(Y)). \quad (2)$$

Obsérvese que la relación (2) no se obtiene a partir de la (1) dejando en aquella $X - E(X)$, puesto que en ambas relaciones los papeles de X e Y aparecen cambiados. La relación (2) se obtiene considerando a X como variable casual, mientras que en la (1) este papel viene desempeñado por Y .

Un procedimiento análogo permitiría aproximar la relación entre X e Y mediante un polinomio de grado n , por ejemplo, $Y = a + bX + cX^2 + dX^3$, para $n=3$.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, a las cantidades

$$Y_{X/X} = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} \quad \text{y} \quad X_{Y/X} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

se les designa coeficientes de regresión lineal de Y sobre X y X sobre Y respectivamente, para el caso.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, se define el coeficiente de correlación lineal entre X e Y , mediante

$$\rho = \frac{\text{Cov}(X, Y)}{(\text{Var}(X) \text{Var}(Y))^{1/2}}$$

a

$$\rho^2 = Y_{X/X} \cdot X_{Y/X}$$

se le denomina coeficiente de determinación. Obsérvese que el signo de ρ es el mismo que el de la $\text{Cov}(X, Y)$.

DEFINICIÓN - Decimos que dos variables X e Y son independientes si y sólo si $\rho = 0$.

Otramente, si $\text{Cov}(X, Y) = 0$, entonces $\rho = 0$ y las variables son independientes. Posteriormente, cuando introduzcamos el concepto de independencia entre variables, volveremos sobre este concepto.

A continuación estudiaremos algunas propiedades básicas del coeficiente de correlación.

PROPIEDAD 1 - a) El coeficiente de correlación lineal entre X e Y satisface la relación

$$|\rho| \leq 1.$$

b) la igualdad $\rho = \pm 1$ se verifica si existen constantes a y b tales que

$$P\{Y = aX + b\} = 1.$$

Demostración - a) Recordemos que de acuerdo con la desigualdad de Cauchy-Schwarz

$$[\text{Cov}(X, Y)]^2 \leq \text{Var}(X) \text{Var}(Y).$$

y de aquí la desigualdad del enunciado.

b) Además, recordemos que si $\rho = \pm 1$, entonces $[\text{Cov}(X, Y)]^2 = \text{Var}(X) \text{Var}(Y)$

EL PRINCIPIO DE LOS MÍNIMOS CUADRADOS

(9)

Sean X e Y dos variables aleatorias de manera que existe entre ellas una relación de dependencia que debemos determinar. Supongamos que la relación funcional entre ambas, ~~es una función~~ ~~que~~ $E(Y^2)$ y $E[h(X)^2]$ son finitas, vamos a buscar de minimizar una función $h(x)$ que aproxime el valor de la relación funcional entre X e Y .

El principio de los mínimos cuadrados consiste en la elección de $h(x)$ de tal suerte que la cantidad

$$E\{Y - h(X)\}^2$$

sea mínima. ¿cómo ha de ser entonces $h(x)$?

Observemos que, si (X, Y) es un vector aleatorio continuo, tenemos

$$\begin{aligned} E\{Y - h(X)\}^2 &= \int_{\mathbb{R}^2} [Y - h(x)]^2 f(x, y) dx dy = \int_{\mathbb{R}^2} [Y - h(x)]^2 f_{Y/X}(y) f_X(x) dy dx = \\ &= \int_{\mathbb{R}} f_X(x) \left\{ \int_{\mathbb{R}} [Y - h(x)]^2 f_{Y/X}(y) dy \right\} dx, \end{aligned}$$

que sea mínima esta expresión supone que se minimiza lo que figura entre llaves en el integrando y de acuerdo con las propiedades estudiadas para la variancia, dicha cantidad se minimiza si cuando $h(x) = E(Y/X)$.

Un resultado análogo se verifica por el caso en que (X, Y) es discreto.

DEFINICIÓN - la relación $y = E(Y/x)$ se conoce como la región de Y sobre X , análogamente $x = E(X/y)$ es la región de X sobre Y .

LÍNEA DE REGRESIÓN - En realidad, por razones de sencillez fundamentalmente, resulta interesante en aproximar la relación entre X e Y mediante una línea recta, $y = ax + b$. En esta situación y haciendo uso del principio de los mínimos cuadrados antes citado, a y b deberán ser elegidos de manera que

$$L = E\{Y - aX - b\}^2$$

sea mínimo. Siempre bajo el supuesto de la existencia de $E(X^2)$ y $E(Y^2)$, la elección de a y b reduce a un problema de máximos y mínimos, buscando en derivar parcialmente L respecto a ambos parámetros e igualar, posteriormente, a cero dichas derivadas. Se obtienen así para a y b , las expresiones

$$a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}, \quad b = E(Y) - E(X) \cdot \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

haciendo la ecuación de la recta, conocida como línea de regresión de Y sobre X ,

$$Y - E(Y) = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} (X - E(X)). \quad (1)$$

Una expresión análoga se obtiene para la línea de regresión de X sobre Y , a saber (10)

$$X - E(X) = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} (Y - E(Y)). \quad (2)$$

Obsérvese que la relación (2) no se obtiene a partir de la (1) dejando en aquella $X - E(X)$, puesto que en ambas relaciones los papeles de X e Y aparecen cambiados. La relación (2) se obtiene considerando a X como variable casual, mientras que en la (1) este papel viene desempeñado por Y .

Un procedimiento análogo permitiría aproximar la relación entre X e Y mediante un polinomio de grado n , por ejemplo, $y = a + bx + cx^2 + dx^3$, para $n=3$.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, a las cantidades

$$r_{Y/X} = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} \quad \text{y} \quad r_{X/Y} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

se designa coeficientes de regresión lineal de Y sobre X y X sobre Y respectivamente, para el caso.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, se define el coeficiente de correlación lineal entre X e Y , mediante

$$\rho = \frac{\text{Cov}(X, Y)}{(\text{Var}(X) \text{Var}(Y))^{1/2}}$$

a

$$\rho^2 = r_{Y/X} \cdot r_{X/Y}$$

se le denomina coeficiente de determinación. Obsérvese que el signo de ρ es el mismo que el de la $\text{Cov}(X, Y)$.

DEFINICIÓN - Decimos que dos variables X e Y son independientes si y sólo si $\rho = 0$.

Otramente, si $\text{Cov}(X, Y) = 0$, entonces $\rho = 0$ y las variables son independientes. Posteriormente, cuando introduzcamos el concepto de independencia entre variables, volveremos sobre este concepto.

A continuación estudiaremos algunas propiedades básicas del coeficiente de correlación.

PROPIEDAD 1 - a) El coeficiente de correlación lineal entre X e Y satisface la relación

$$|\rho| \leq 1.$$

b) la igualdad $\rho = \pm 1$ se verifica si existen constantes a y b tales que

$$P\{Y = aX + b\} = 1.$$

Demostración - a) Recordemos que de acuerdo con la desigualdad de Cauchy-Schwarz

$$[\text{Cov}(X, Y)]^2 \leq \text{Var}(X) \text{Var}(Y).$$

y de aquí la desigualdad del enunciado.

b) Además, recordemos que si $\rho = \pm 1$, entonces $[\text{Cov}(X, Y)]^2 = \text{Var}(X) \text{Var}(Y)$

que como ni ρ ni $P\{aX+Y=0\}=1$, que es de la forma $P\{Y=aX+b\}=1$, mediante una adecuada transformación de Y . (11)

Corolario.- Las dos líneas de regresión (1) y (2) coinciden si y sólo si $\rho = 1$ o $\rho = -1$.

Propiedad 2.- Sean $E(X^2) < +\infty$, $E(Y^2) < +\infty$ y hagamos $U = aX+b$, $V = cY+d$, entonces

$$\rho_{X,Y} = \pm \rho_{U,V},$$

donde $\rho_{X,Y}$ y $\rho_{U,V}$ son, respectivamente, los coeficientes de correlación lineal de X y Y y de U y V .

Demostración.- La propiedad se deduce de las propiedades de los momentos ya estudiadas.

EJEMPLOS

(1) Sea (X,Y) un vector aleatorio con función de densidad conjunta

$$f(x,y) = \begin{cases} x+y & , 0 < x < 1, 0 < y < 1 \\ 0 & , \text{en el resto.} \end{cases}$$

Entonces

$$\begin{aligned} E(X^l Y^m) &= \int_0^1 \int_0^1 x^l y^m (x+y) dx dy = \int_0^1 \int_0^1 x^{l+1} y^m dx dy + \int_0^1 \int_0^1 x^l y^{m+1} dx dy \\ &= \frac{1}{(l+2)(m+1)} + \frac{1}{(l+1)(m+2)}; \text{ en } l, m \text{ enteros positivos.} \end{aligned}$$

A partir de este resultado, tenemos

$$l=1, m=0, \quad E(X) = \frac{7}{12}, \quad l=0, m=1, \quad E(Y) = \frac{7}{12}.$$

$$l=2, m=0, \quad E(X^2) = \frac{5}{12}, \quad l=0, m=2, \quad E(Y^2) = \frac{5}{12}$$

$$\text{Var}(X) = \frac{5}{12} - \frac{49}{144} = \frac{11}{144} = \text{Var}(Y)$$

$$\text{Cov}(X,Y) = E(XY) - E(X)E(Y) = \frac{1}{3} - \frac{49}{144} = \frac{48-49}{144} = -\frac{1}{144}.$$

(2) Repetimos el ejemplo 5 (pag. 8 de lectura de cálculo). El vector aleatorio (X,Y) , con f.d.p. conjunta

$$f(x,y) = \begin{cases} 2 & , 0 < x < y < 1 \\ 0 & , \text{en el resto} \end{cases}$$

teniendo por densidades marginales $f_1(x) = 2(1-x)$, $0 < x < 1$
0, en el resto

$$y \quad f_2(y) = 2y \quad , \quad 0 < y < 1 \\ 0 \quad , \quad \text{en el resto.} \quad (12)$$

Asimismo las funciones de densidad condicionales vienen dadas por (véase ejemplo 7, pag. 13 del mismo capítulo)

$$f_{Y/X}(y) = \frac{1}{y} \quad , \quad 0 < x < y$$

$$f_{X/Y}(x) = \frac{1}{1-x} \quad , \quad x < y < 1.$$

En ambos casos se trata de distribuciones de probabilidades uniformes en el correspondiente intervalo. A partir de aquí

$$E(Y/X) = \int_x^1 y f_{Y/X}(y) dy = \int_x^1 y \cdot \frac{1}{1-x} dy = \frac{1}{1-x} \cdot \frac{1-x^2}{2} = \frac{1+x}{2}, \quad 0 < x < 1.$$

$$E(X/Y) = \int_0^y x f_{X/Y}(x) dx = \int_0^y x \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^2}{2} = \frac{y}{2}, \quad 0 < y < 1.$$

Análogamente

$$E(X^2/Y) = \int_0^y x^2 \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^3}{3} = \frac{y^2}{3}, \quad 0 < y < 1$$

y por tanto

$$\text{Var}(X/Y) = E(X^2/Y) - [E(X/Y)]^2 = \frac{y^2}{3} - \frac{y^2}{4} = \frac{y^2}{12}, \quad 0 < y < 1$$

Por otra parte

$$\begin{aligned} E(X) &= \int_0^1 x f_1(x) dx = \int_0^1 x \cdot 2(1-x) dx = \int_0^1 (2x - 2x^2) dx = \left[x^2 - \frac{2x^3}{3} \right]_0^1 = \\ &= 1 - \frac{2}{3} = \frac{1}{3} \end{aligned}$$


pero

$$E\left(E\left(\frac{X}{Y}\right)\right) = \int_0^1 E\left(\frac{X}{Y}\right) f_2(y) dy = \int_0^1 \frac{y}{2} \cdot 2y dy = \int_0^1 y^2 dy = \left[\frac{y^3}{3} \right]_0^1 = \frac{1}{3},$$

que coincide, como ya sabemos, con $E(X)$.

- ③ La igualdad $E(X) = E(E(X/Y))$ es en ocasiones muy útil para obtener la primera de las esperanzas a partir de la segunda, cuando la obtención directa de ella es complicada. Veamos el siguiente ejemplo:

"Un trabajador opera con determinado tipo de máquinas en un número n . Las máquinas están alineadas y separadas entre sí una distancia a . Supongamos que el operador se traslada de una máquina a otra según un orden de prioridad totalmente aleatorio. Encontrar la longitud media del camino que recorre el operador para atender dos máquinas consecutivamente".



Numéramos las máquinas de izquierda a derecha, de 1 a n , y denotemos por B_k el suceso "el operador está atendiendo la máquina k ". Puesto que las máquinas son todas del mismo tipo, el orden de prioridad es aleatorio, la probabilidad P_i^k , de que la próxima máquina en requerir los servicios del operador sea la i , es $1/n$ ($1 \leq i \leq n$). La longitud del camino que deberá recorrer el operador para atender dicha máquina, vendrá dada por

$$\lambda_i^k = \begin{cases} (k-i)a, & k \geq i \\ (i-k)a, & k < i \end{cases}$$

denotando por λ la v.a. correspondiente, tenemos

$$\begin{aligned} E(\lambda/B_k) &= \sum_{i=1}^n \lambda_i^k \cdot P_i^k = \frac{1}{n} \left[\sum_{i=1}^k (k-i)a + \sum_{i=k+1}^n (i-k)a \right] = \\ &= \frac{a}{n} \left[\frac{k(k-1)}{2} + \frac{(n-k)(n-k+1)}{2} \right] = \frac{a}{2n} [2k^2 - 2k(n+1) + n(n+1)] \end{aligned}$$

Por otra parte la probabilidad de que el operador esté atendiendo a la máquina k , es la misma para todos los k , es decir $P(B_k) = \frac{1}{n}$, $1 \leq k \leq n$, de acuerdo con esto

$$\begin{aligned} E(\lambda) &= E[E(\lambda/B_k)] = \sum_{k=1}^n E(\lambda/B_k) \cdot P(B_k) = \\ &= \sum_{k=1}^n \frac{a}{2n^2} [2k^2 - 2k(n+1) + n(n+1)] = \frac{a}{2n^2} \left[2 \sum_{k=1}^n k^2 - 2(n+1) \sum_{k=1}^n k + n^2(n+1) \right] \\ &= \frac{a}{2n^2} \left[2 \cdot \frac{n(n+1)(2n+1)}{6} - 2(n+1) \cdot \frac{n(n+1)}{2} + n^2(n+1) \right] = \end{aligned}$$

$$\begin{aligned} &= \frac{a}{2n^2} \left[\frac{n(n+1)(2n+1)}{3} - n(n+1) \right] = \frac{a}{2n^2} \left[n(n+1) \left\{ \frac{2n+1}{3} - 1 \right\} \right] = \\ &= \frac{a}{2n^2} \cdot \frac{n(n+1)}{3} \cdot (2n-2) = \frac{2an}{6n^2} (n^2-1) = \frac{a(n^2-1)}{3n} = \frac{a(n+1)}{3n} = \boxed{\frac{a}{3} \left(1 + \frac{1}{n} \right)} \end{aligned} \quad (14)$$

- ④ Sea (X, Y) un vector aleatorio con densidad conjunta dada por

$$f(x, y) = \begin{cases} e^{-y} & , 0 < x < y < +\infty \\ 0 & , \text{en el resto.} \end{cases}$$

las correspondientes marginales vendrán dadas por

$$f_1(x) = \int_{\mathbb{R}} f(x, y) dy = \int_x^{+\infty} e^{-y} dy = (-e^{-y})_x^{+\infty} = e^{-x}, \quad 0 < x < +\infty \\ = 0, \quad \text{en el resto.}$$

$$f_2(y) = \int_{\mathbb{R}} f(x, y) dx = \int_0^y e^{-y} dx = e^{-y} \cdot y, \quad 0 < y < +\infty \\ = 0, \quad \text{en el resto.}$$

A partir de aquí las densidades condicionales se obtienen fácilmente,

$$f_{X/Y}(x) = \frac{f(x, y)}{f_2(y)} = \frac{e^{-y}}{e^{-y} \cdot y} = \frac{1}{y}, \quad 0 < x < y \\ = 0, \quad \text{en el resto.}$$

$$f_{Y/X}(y) = \frac{f(x, y)}{f_1(x)} = \frac{e^{-y}}{e^{-x}} = e^{x-y}, \quad x < y < +\infty \\ = 0, \quad \text{en el resto.}$$

Entonces

$$E(X/Y) = \int_{\mathbb{R}} x f_{X/Y}(x) dx = \int_0^y x \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^2}{2} = \frac{y}{2}, \quad 0 < y < +\infty$$

$$E(Y/X) = \int_{\mathbb{R}} y f_{Y/X}(y) dy = \int_x^{+\infty} y \cdot e^{x-y} dy = \int_0^{+\infty} (u+x) e^{-u} du = x+1, \quad 0 < x < +\infty$$

En este caso la relación entre X e Y , por un lado en ambos casos, considerando con las líneas de ruptura de X sobre Y e Y sobre X . De acuerdo con esto los coeficientes de regresión

Capítulo 9

Algunos teoremas de convergencia

ALGUNOS TEOREMAS DE CONVERGENCIA

Antes de comenzar el capítulo de funciones características, enunciaremos algunos teoremas que proporcionan las condiciones mediante las cuales existe pasando la integración y el paso al límite cuando trabajamos con familias de funciones medibles. Muchos de estos teoremas de convergencia, por así decirlo, deben su origen a los que que fue quien resumió en primer lugar, al menos con cierto rigor y sistematización, de la teoría de la medida y de la integración abstracta, de aquí que muchos de estos teoremas lleven su nombre.

TEOREMA DE LA CONVERGENCIA MONOTONA DE LEBESGUE. - Sea $\{f_n\}$ una sucesión monótona creciente de funciones medibles no negativas tales que $\lim_n f_n = f$. Entonces

$$\lim_n \int_{\mathbb{R}} f_n d\mu = \int_{\mathbb{R}} \lim_n f_n d\mu = \int_{\mathbb{R}} f d\mu.$$

(El enunciado del teorema también es válido si la convergencia de las funciones es casi por todas partes).

COROLARIO. - Sea $f_n \geq 0$, f_n y sea $f = \sum_{n=1}^{\infty} f_n$, entonces la sucesión $g_n = \sum_{i=1}^n f_i$ verifica las condiciones del teorema anterior y podemos escribir

$$\int_{\mathbb{R}} \sum_{n=1}^{\infty} f_n d\mu = \int_{\mathbb{R}} \lim_n g_n d\mu = \lim_n \int_{\mathbb{R}} g_n d\mu = \lim_n \int_{\mathbb{R}} \sum_{i=1}^n f_i d\mu = \int_{\mathbb{R}} f d\mu$$

Del teorema de la convergencia monótona de Lebesgue se derivan a su vez el conocido lema

LEMA DE FATOU. - Para funciones medibles no negativas, f_n , se verifica siempre

$$\int_{\mathbb{R}} \liminf_n f_n d\mu \leq \liminf_n \int_{\mathbb{R}} f_n d\mu.$$

donde $\liminf_n$ denota el límite inferior.

A su vez el lema de Fatou permite obtener el otro importante teorema de convergencia, válido ahora para cualquier familia de funciones medibles

TEOREMA DE LA CONVERGENCIA DOMINADA DE LEBESGUE. - Sean f_n funciones medibles tales que $|f_n| \leq g$, (casi por todas partes), donde g es una función medible integrable. Además $f_n \rightarrow f$ (casi por todas partes), entonces f y f_n son integrables y además

$$\lim_n \int_{\mathbb{R}} f_n d\mu = \int_{\mathbb{R}} f d\mu.$$

①

Si en este teorema reemplazamos la función g por una constante positiva y exigimos además que la medida sea finita, entonces

$$\int_{\mathbb{R}} M d\mu = M \cdot \mu(\mathbb{R}) < +\infty$$

lo que supone que M es una función integrable. Obtenemos entonces un nuevo teorema que se conoce como el

TEOREMA DE LA CONVERGENCIA ACOTADA. - Si $\mu(\mathbb{R}) < +\infty$ y las f_n están uniformemente acotadas, entonces $f_n \rightarrow f$ (casi por todas partes) implica que $\lim_n \int_{\mathbb{R}} f_n d\mu = \int_{\mathbb{R}} f d\mu$

Del igual que para el el teorema de la convergencia monótona, también para el de la convergencia dominada existe, como es obvio, una versión para series, a saber

COROLARIO DEL T.C.D. - Si $\sum_{n=1}^{\infty} f_n$ converge (casi por todas partes) y $\sum_{n=1}^{\infty} |f_n| \leq g$ (casi por todas partes), donde g es una función integrable, entonces $\sum_{n=1}^{\infty} f_n$ es integrable y tenemos

$$\int_{\mathbb{R}} \sum_{n=1}^{\infty} f_n d\mu = \sum_{n=1}^{\infty} \int_{\mathbb{R}} f_n d\mu.$$

OBSERVACION. - Si bien todos estos teoremas han sido enunciados para series, se demuestra que son también válidos para conjuntos de índices cualesquiera

Como consecuencia de esta observación enunciamos finalmente un teorema, bastante de utilidad en el estudio de las funciones características, y que resuelve el problema de derivar una integral mediante la derivación bajo el integrando.

TEOREMA. - Supongamos que $f(\omega, t)$ es una función medible para cada $t \in [a, b]$.

- 1) Supongamos que $f(\omega, t)$ es continua (casi por todas partes) para todo ω , y supongamos además que para cada t perteneciente a un intervalo I , $|f(\omega, t)| \leq g(\omega)$ (casi por todas partes), siendo g integrable. Entonces $\int_{\mathbb{R}} f(\omega, t) d\mu$ es continua para todo t .
- 2) Supongamos que para $\omega \in A$ (A medible tal que $\mu(A) < +\infty$), $f(\omega, t)$ tiene en $[a, b]$ derivada, $f'(\omega, t)$, respecto de t . Supongamos además que $|f'(\omega, t)| \leq g(\omega)$, $\omega \in A$ y $t \in [a, b]$, siendo g integrable. Entonces

$$\frac{d}{dt} \int_{\mathbb{R}} f(\omega, t) d\mu = \int_{\mathbb{R}} f'(\omega, t) d\mu, \quad t \in [a, b].$$

Capítulo 10

Función característica

FUNCION CARACTERISTICA

①

Existen determinados problemas en teoría de la Probabilidad de difícil y complicada solución, concretamente los problemas relacionados con el estudio de las distribuciones límite y la distribución de probabilidad de suma de variables aleatorias. Una solución relativamente sencilla a estos problemas se obtiene mediante el uso de las funciones características, funciones que se deducen de la aplicación de técnicas clásicas del análisis matemático, la transformada de Fourier, a la teoría de la Probabilidad. Todo lo que vamos a hacer en este capítulo es repasar los puntos de estas funciones características.

DEFINICION.- Sea X una variable aleatoria, se define la función característica de la v.a. X como $E(e^{itx})$. A dicha función se la denota mediante $\varphi_X(t)$, o bien $\varphi(t)$ si no existe confusión posible.

De acuerdo con la definición de esperanza y según las características de la v.a. X , la función característica de X se obtendrá mediante:

a) X continua

$$\varphi(t) = \int_{-\infty}^{+\infty} e^{itx} f(x) dx.$$

b) X discreta

$$\varphi(t) = \sum_{x \in A} e^{itx} \cdot f(x), \text{ donde } A \text{ tal que } P(X \in A) = 1.$$

Sabemos de inmediato que la función característica de cualquier v.a. existe siempre, por cuanto la correspondiente esperanza que la define siempre la tiene ya que la función e^{itx} está acotada, $|e^{itx}| \leq 1$, y por tanto es integrable.

A continuación vamos a enumerar las propiedades más importantes de las funciones características, en forma de teoremas.

PROPIEDADES DE LAS FUNCIONES CARACTERISTICAS.

TEOREMA 1.- Una función característica es uniformemente continua en $\mathbb{R}$, además cumple

$$\varphi(0) = 1, |\varphi(t)| \leq 1, t \in \mathbb{R}.$$

Demostración.- En efecto

$$\varphi(0) = E(e^{i0x}) = E(1) = 1$$

por otra parte

$$|\varphi(t)| = \left| \int_{\Omega} e^{itx} dP \right| \leq \int_{\Omega} |e^{itx}| \cdot dP \leq \int_{\Omega} 1 \cdot dP = P(\Omega) = 1.$$

Comprobemos la continuidad uniforme. Estudiemos para ello la diferencia ②

$$\varphi(t+h) - \varphi(t), \text{ tenemos}$$

$$\varphi(t+h) - \varphi(t) = \int_{\Omega} e^{i(t+h)x} dP - \int_{\Omega} e^{itx} dP = \int_{\Omega} e^{itx} (e^{ihx} - 1) dP$$

entonces

$$|\varphi(t+h) - \varphi(t)| \leq \int_{\Omega} |e^{itx} (e^{ihx} - 1)| dP \leq \int_{\Omega} |e^{ihx} - 1| dP = E(|e^{ihx} - 1|)$$

$$\text{pero } |e^{ihx} - 1| \leq |e^{ihx}| + |1| = 2$$

por tanto $E(|e^{ihx} - 1|) \leq E(2) = 2$, entonces es lícito pasar al límite y la integración, de acuerdo con los teoremas de convergencia, tendremos que

$$\lim_{h \rightarrow 0} |\varphi(t+h) - \varphi(t)| \leq \lim_{h \rightarrow 0} E(|e^{ihx} - 1|) = E\left(\lim_{h \rightarrow 0} |e^{ihx} - 1|\right) = E(0) = 0$$

y por tanto se da la continuidad uniforme.

TEOREMA 2.- Si $Y = aX + b$, donde a, b son constantes, entonces

$$\varphi_Y(t) = e^{ibt} \cdot \varphi_X(at).$$

Demostración.-

$$\begin{aligned} \varphi_Y(t) &= E(e^{itY}) = E(e^{it(ax+b)}) = E(e^{itb} \cdot e^{itaX}) = e^{itb} \cdot E(e^{itaX}) = \\ &= e^{itb} \cdot \varphi_X(at). \end{aligned}$$

TEOREMA 3.- Si una variable aleatoria X tiene un momento absoluto de orden n , entonces su función característica es diferenciable n veces y para $k \leq n$, tenemos

$$\varphi^{(k)}(0) = i^k \cdot E(X^k).$$

Demostración.- Derivando la función característica k veces, $k \leq n$, tenemos

$$\varphi^{(k)}(t) = i^k \int_{\Omega} x^k \cdot e^{itx} dP$$

Pero

$$\left| \int_{\Omega} x^k \cdot e^{itx} dP \right| \leq \int_{\Omega} |x^k| \cdot dP$$

y por tanto, de acuerdo con la hipótesis del teorema, $\varphi^{(k)}(t)$ existe, la derivación

sta' permitida. Haciendo $t=0$, tenemos

$$\Psi^{(k)}(0) = i^k \int_{-\infty}^{\infty} x^k dP = i^k \cdot E(x^k).$$

Apoyándonos en ste lema y mediante el logaritmo de la función característica podemos obtener una sencilla y muy útil expresión para la media, la variancia de una variable aleatoria. En efecto, sea

$$\Psi(t) = \log \varphi(t)$$

entonces

$$\Psi'(t) = \frac{\varphi'(t)}{\varphi(t)}$$

y derivando nuevamente

$$\Psi''(t) = \frac{\varphi''(t) \cdot \varphi(t) - [\varphi'(t)]^2}{[\varphi(t)]^2}$$

teniendo en cuenta que $\varphi(0) = 1$ y de acuerdo con el lema anterior,

$$\Psi'(0) = \varphi'(0) = i \cdot E(x)$$

$$\Psi''(0) = \varphi''(0) - [\varphi'(0)]^2 = i^2 E(x^2) - [i E(x)]^2 = -\text{var}(x),$$

de aquí

$$E(x) = \frac{1}{i} \Psi'(0)$$

$$\text{var}(x) = -\Psi''(0).$$

A la densidad k -ésima de $\Psi(t)$ ^{multiplicado por i^k} se la conoce como el cumulante (o semi-invariante) de k -ésimo orden de la variable aleatoria. Este cumulant es una función de los k primeros momentos de la variable. Por ejemplo,

$$i^3 \Psi'''(0) = -\{E(x^3) - 3E(x^2) \cdot E(x) + 2(E(x))^3\}.$$

FORMULA DE INVERSION Y TEOREMA DE UNICIDAD

Hemos visto que a partir de la distribución de probabilidad de una f.a. X se siempre puede determinar su función característica. Será importante que la proposición inversa también sea cierta. Es o lo que tentamos de establecer con el siguiente lema

FORMULA DE INVERSION DE LEVY. Sean F y φ la función de distribución y característica, respectivamente, de una variable aleatoria X . Se verifica entonces:

$$F(b) - F(a) = \lim_{T \rightarrow \infty} \frac{1}{2\pi} \int_{-T}^T \frac{e^{-itb} - e^{-ita}}{t} \varphi(t) dt, \text{ o bien la equivalente}$$

(3)

$$F(x_0 + h) - F(x_0 - h) = \lim_{T \rightarrow \infty} \frac{1}{\pi} \int_{-T}^T \frac{\sin ht}{t} e^{-itx_0} \cdot \varphi(t) dt.$$

sólo que a, b sean puntos de continuidad de F ($\circ$ $x_0 + h, x_0 - h$).

Demostración. - Sea

$$J = \frac{1}{\pi} \int_{-T}^T \frac{\sin ht}{t} \cdot e^{-itx_0} \varphi(t) dt = \frac{1}{\pi} \int_{-T}^T \frac{\sin ht}{t} e^{-itx_0} \left[\int_R e^{itx} dP' \right] dt$$

donde $\int_R e^{itx} dP' = E(e^{itx})$, siendo P' la probabilidad inducida por P , mediante

X en R . Podemos también escribir J de la siguiente forma

$$J = \frac{1}{\pi} \int_{-T}^T \left[\int_R \frac{\sin ht}{t} \cdot e^{it(x-x_0)} dP' \right] dt$$

pero

$$\left| \frac{\sin ht}{t} \cdot e^{it(x-x_0)} \right| \leq \left| \frac{\sin ht}{t} \right| < h \quad \text{y} \quad \int_R dP' = h$$

en definitiva la función $\frac{\sin ht}{t} \cdot e^{it(x-x_0)}$ es integrable (T finito) y por tanto podemos aplicar el lema de Fubini para permutar el orden de integración, y así

$$\begin{aligned} J &= \frac{1}{\pi} \int_R dP' \int_{-T}^T \frac{\sin ht}{t} \cdot e^{it(x-x_0)} dt = \frac{1}{\pi} \int_R dP' \int_{-T}^T \frac{\sin ht}{t} (\cos t(x-x_0) + i \sin t(x-x_0)) dt = \\ &= \frac{2}{\pi} \int_R dP' \int_0^T \frac{\sin ht}{t} \cdot \cos t(x-x_0) dt \end{aligned}$$

aplicando la fórmula $\sin \alpha \cdot \cos \beta = \frac{1}{2} [\sin(\alpha+\beta) + \sin(\alpha-\beta)]$, un $\alpha = ht$, $\beta = t(x-x_0)$,

$$\begin{aligned} J &= \frac{2}{\pi} \int_R dP' \int_0^T \frac{1}{2t} [\sin t(x-x_0+h) + \sin t(x-x_0-h)] dt = \frac{1}{\pi} \int_R dP' \left[\int_0^T \frac{\sin t(x-x_0+h)}{t} dt - \right. \\ &\quad \left. - \int_0^T \frac{\sin t(x-x_0-h)}{t} dt \right] = \frac{1}{\pi} \int_R g(x, T) dP' \end{aligned}$$

donde $g(x, T)$ es la función que figura entre corchetes en el anterior miembro de la igualdad.

(4)

Por el cálculo integral obtenemos que:

$$\lim_{T \rightarrow \infty} \int_0^T \frac{\sin \alpha x}{x} dx = \frac{\pi}{2} \quad \text{y está acotada para todo } T > 0$$

Por otra parte

$$\int_0^T \frac{\sin \alpha x}{x} dx = \int_0^{KT} \frac{\sin y}{y} dy$$

En consecuencia

$$\lim_{T \rightarrow \infty} \frac{1}{\pi} \int_0^T \frac{\sin \alpha x}{x} dx = \begin{cases} 1, & \alpha > 0 \\ 0, & \alpha = 0 \\ -1, & \alpha < 0 \end{cases}$$

aplicando este resultado a la función $g(x, T)$, tenemos:

$$\lim_{T \rightarrow \infty} \frac{1}{\pi} g(x, T) = \begin{cases} 0, & x < x_0 - h \\ 1/2, & x = x_0 - h \\ 1, & x_0 - h < x < x_0 + h \\ 1/2, & x = x_0 + h \\ 0, & x > x_0 + h \end{cases}$$

además $|g(x, T)|$ está acotado y podemos hacer uso de los teoremas de convergencia para pasar la integración y el paso al límite. Tendremos en definitiva:

$$\lim_{T \rightarrow \infty} J = \lim_{T \rightarrow \infty} \frac{1}{\pi} \int_R g(x, T) dP' = \frac{1}{\pi} \int_R \lim_{T \rightarrow \infty} g(x, T) dP' = \int_{x_0-h}^{x_0+h} dP' = F(x_0+h) - F(x_0-h)$$

no olvidemos que P' define F de la forma ya indicada y que x_0+h , x_0-h son puntos de continuidad de F .

COROLARIO. Si la función característica es absolutamente integrable en $\mathbb{R}$, entonces la función de distribución es absolutamente continua, su derivada es continua y tenemos

$$f(x) = F'(x) = \frac{1}{2\pi} \int_{\mathbb{R}} e^{-itx} \varphi(t) dt.$$

Demostración. En efecto

$$\frac{F(x_0+h) - F(x_0-h)}{2h} = \frac{1}{2\pi} \int_{\mathbb{R}} \frac{\sin ht}{ht} \cdot e^{-itx_0} \varphi(t) dt$$

tenemos que

$$\left| \frac{\sin ht}{ht} \cdot e^{-itx_0} \cdot \varphi(t) \right| \leq |\varphi(t)|$$

y como $|\varphi(t)|$ es integrable, podemos pasar el paso al límite con la integración, obteniendo

$$\lim_{h \rightarrow 0} \frac{F(x_0+h) - F(x_0-h)}{2h} = f(x_0) = F'(x_0) = \frac{1}{2\pi} \int_{\mathbb{R}} e^{-itx_0} \varphi(t) dt.$$

⑤

Existe pues la derivada de $F(x)$ para todo sin puntos de discontinuidad. Por otra parte la continuidad absoluta deriva del hecho de poder escribir

$$F(x_0+h) - F(x_0-h) \leq 2h \cdot \frac{1}{2\pi} \int_{\mathbb{R}} |\varphi(t)| dt$$

que podemos hacer tan pequeño como queramos eligiendo h adecuadamente.

Finalmente, para comprobar la continuidad de F , tendremos

$$|F(x_0+h) - F(x)| = \frac{1}{2\pi} \left| \int_{\mathbb{R}} \frac{e^{-itx} - e^{-it(x_0+h)}}{t} \varphi(t) dt \right| \leq \frac{1}{2\pi} \int_{\mathbb{R}} |e^{-itx} - 1| \cdot |\varphi(t)| dt$$

$$\text{pero } |e^{-itx} - 1| = |\cos tx - i \sin tx - 1| = |(\cos tx - 1) - i \sin tx| = \sqrt{(\cos tx - 1)^2 + \sin^2 tx} = \sqrt{2 \cos^2 tx - 2 \cos tx + 1} = \sqrt{2(1 - \cos tx)} = \sqrt{2 \cdot 2 \sin^2 \frac{tx}{2}} = 2 \left| \sin \frac{tx}{2} \right|$$

luego

$$|F(x_0+h) - F(x)| \leq \frac{1}{2\pi} \int_{\mathbb{R}} 2 \left| \sin \frac{th}{2} \right| \cdot |\varphi(t)| dt,$$

pero como la integral es finita, podemos elegir A tal que, dado $\varepsilon > 0$,

$$\frac{1}{2\pi} \int_{\mathbb{R}} 2 \left| \sin \frac{th}{2} \right| \cdot |\varphi(t)| dt = \frac{1}{2\pi} \int_{|t| \leq A} 2 \left| \sin \frac{th}{2} \right| \cdot |\varphi(t)| dt + \frac{1}{2\pi} \int_{|t| > A} 2 \left| \sin \frac{th}{2} \right| \cdot |\varphi(t)| dt$$

La segunda integral del segundo miembro no hemos que $\varepsilon/2$ y la primera función $\sin$ que de A es acotada. (Obsérvese que hemos usado la continuidad uniforme).

La fórmula de inversión no permite demostrar uno de los resultados más importantes del capítulo, el llamado teorema de unicidad.

TEOREMA DE UNICIDAD. Existe una correspondencia biunívoca entre la función de distribución y la función característica de una variable aleatoria.

Demostración. Ya sabemos, por definición, que toda función de distribución da lugar a una función característica.

Si φ es la función característica de X , que tiene a F por función de distribución, entonces por el teorema de inversión sabemos que

$$F(x) - F(y) = \lim_{T \rightarrow \infty} \frac{i}{2\pi} \int_{-T}^T \frac{e^{-itx} - e^{-ity}}{t} \varphi(t) dt, \quad \text{para } x \neq y \text{ pto. de continuidad de } F.$$

por tanto

$$F(x) = \lim_{y \rightarrow x} \lim_{T \rightarrow \infty} \frac{i}{2\pi} \int_{-T}^T \frac{e^{-itx} - e^{-ity}}{t} \varphi(t) dt$$

donde el paso al límite en y se lleva a cabo a través de puntos de continuidad de F ,
una que siempre lo puede. tenemos pues a F determinada salvo en los puntos de dis-
continuidad, pero en ellos podemos actuar como sigue:

Sea x un pto de discontinuidad de F . Sea $\{x_n\}$ una sucesión de puntos de
continuidad de F tal que $x_n \rightarrow x$, entonces $F(x_n) \rightarrow F(x)$ por ser F continua por la
derecha. Como los $F(x_n)$ determinados anteriormente de acuerdo con lo anterior, también
lo será $F(x)$ ahora del correspondiente límite..

La utilidad de este teorema de unicidad quedará puesta de manifiesto cuando nos ocupemos del
problema de la independencia de variables, y más concretamente de la suma de variables aleatorias
independientes.

OTRA FORMA DEL TEOREMA DE INVERSIÓN

Existe otra manera de presentar el teorema de inversión que es especialmente útil para
determinar la función de densidad en el caso de variables aleatorias discretas. Recordemos antes que
 P' , la probabilidad reducida por P respecto mediante X sobre el espacio medible (R, β) ,
nos servirá a la vez para definir la función de distribución a través de

$$F(b) - F(a) = P'([a, b]) , \text{ o bien } F(x) = P'(-\infty, x])$$

de acuerdo con esto

$$P'(\{a\}) = \lim_{n \rightarrow \infty} P'([a - \frac{1}{n}, a]) = \lim_{n \rightarrow \infty} (F(a) - F(a - \frac{1}{n})) = F(a) - F(a-0)$$

Si F es continua en a , entonces $P'(\{a\}) = 0$, de lo contrario $P'(\{a\}) \neq 0$ y mide el salto que
da la función en dicho punto, que recordemos, equivale al valor de la función de densidad en dicho
punto, por cuanto

$$f(a) = P(X=a) = P'(\{a\}).$$

Hecha esta introducción, que nos será útil posteriormente, examinemos el teorema de inversión en su
nueva forma

TEOREMA. - Sea X una v.a. y sean F y φ la función de distribución y característica, respectiva-
mente. Entonces, para cualquier valor de x_0 tenemos

$$F(x) - F(x_0) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T e^{-itx_0} \varphi(t) dt.$$

Demostración. -

$$\frac{1}{2T} \int_{-T}^T e^{-itx_0} \varphi(t) dt = \frac{1}{2T} \int_{-T}^T e^{-itx_0} \left[\int_{-T}^T e^{itx} dP' \right] dt$$

dada la integrabilidad de la función podemos aplicar el teorema de Fubini y permutar
el orden de integración, de manera que

$$\begin{aligned} \frac{1}{2T} \int_{-T}^T e^{-itx_0} \left[\int_{-T}^T e^{itx} dP' \right] dt &= \frac{1}{2T} \int_{-T}^T \left[\int_{-T}^T e^{it(x-x_0)} dt \right] dP' = \frac{1}{2T} \int_{-T}^T dP' \left[\int_{-T}^T (\cos t(x-x_0) + i \sin t(x-x_0)) dt \right] \\ &= \frac{1}{2T} \int_{-T}^T dP' \left[2 \int_0^T \cos t(x-x_0) dt \right] = \frac{1}{T} \int_{-T}^T dP' \left[\frac{\sin t(x-x_0)}{x-x_0} \right]_0^T = \frac{1}{T} \int_{-T}^T dP' \frac{\sin T(x-x_0)}{x-x_0} \end{aligned} \quad (2)$$

pero $\lim_{T \rightarrow \infty} \frac{1}{T} \cdot \frac{\sin T(x-x_0)}{x-x_0} = 0$, si $x \neq x_0$

mientras que

$$\lim_{T \rightarrow \infty} \frac{1}{T} \cdot \frac{\sin T(x-x_0)}{x-x_0} = 1, \text{ si } x = x_0$$

entonces, aplicando el teorema de convergencia que nos permite permutar la integración y el
paso al límite tendremos

$$\lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T e^{-itx_0} \varphi(t) dt = \int_{-T}^T \lim_{T \rightarrow \infty} \frac{\sin T(x-x_0)}{T(x-x_0)} dP' = \int_{\{x_0\}} dP' = P'(\{x_0\})$$

y de acuerdo con lo dicho al principio del párrafo

$$P'(\{x_0\}) = F(x_0) - F(x_0-0).$$

Esta fórmula es especialmente útil para obtener la función de densidad de una variable aleatoria
discreta a partir de su función característica. Recordemos lo dicho en la introducción, aquellos puntos
con probabilidad distinta de cero,

$$f(x) = P(X=x) = P'(\{x\}) = F(x) - F(x-0) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T e^{-itx} \varphi(t) dt.$$

EL CASO DE LAS DISTRIBUCIONES EN REJADO (LATTICE DISTRIBUTIONS)

Definición. Se dice que una variable aleatoria discreta posee una distribución en rejado si el empujado
 $a + bn$, $n = 0, \pm 1, \dots$ genera la distribución. Es decir, si los únicos valores que toma la
variable con probabilidad distinta de cero son de la forma $x = a + bn$, con $n = 0, \pm 1, \dots$
entonces a y b enteros y b positivo.

En muchos los casos de variables de este tipo. Por ejemplo, la Binomial $B(n, p)$ es un caso patia-
lar en la que $a = 0$, $b = 1$, $n = 0, 1, \dots, n_0$. La Poisson y la Binomial negativa son también

distribución en conjunto en la que $a=0$, $b=1$ y $n=0,1,\dots$.

(9)

Este tipo de distribuciones presentan algunas peculiaridades en cuanto a sus funciones características, por ejemplo, puede demostrarse que $\exists t \neq 0$; $|f(t)|=1$, si X es una distribución en conjunto. El recíproco de esta propiedad también es cierto. Otra propiedad que la caracteriza la enunciaremos y demostraremos a continuación.

TEOREMA.- Una variable aleatoria X posee una distribución en conjunto si y solo si su función característica es periódica, con período 2π . Es decir $f(t+2\pi)=f(t)$, $t \in \mathbb{R}$.

Demostración.- Directa. Si X es una distribución en conjunto, entonces $X_n = a + b n$ con un número entero y tendremos

$$f(t) = \sum_n e^{itx_n} \cdot P(X=x_n)$$

$$\text{y } f(t+2\pi) = \sum_n e^{i(t+2\pi)x_n} P(X=x_n) = \sum_n e^{itx_n} \cdot e^{i2\pi x_n} \cdot P(X=x_n)$$

$$\text{pero } e^{ix_n 2\pi} = \cos x_n 2\pi + i \sin x_n 2\pi = 1$$

$$\text{por tanto } f(t+2\pi) = f(t).$$

Inversa. Sea X una variable aleatoria discreta que toma los valores $\{x_n\}_{n \geq 1}$, de manera que su función característica verifica $f(t) = f(t+2\pi)$, entonces

$$f(t) = \sum_n e^{itx_n} P(X=x_n) = \sum_n e^{itx_n} \cdot e^{i2\pi x_n} P(X=x_n) = f(t+2\pi)$$

$$\text{por tanto } e^{ix_n 2\pi} = 1, \forall n$$

y de aquí x_n deberá tomar valores en $\{0, \pm 1, \pm 2, \dots\}$ o en algún conjunto que pueda ponerse en biyección con este.

Para terminar con este tipo de distribuciones de probabilidad estudiaremos la formulación general que el teorema de inversión adquiere en estas variables.

TEOREMA DE INVERSIÓN PARA DISTRIBUCIONES EN ENJUNDO

Si X es una v.a. en distribución en conjunto, entonces su función característica posee inversa. La función de densidad mediante la siguiente fórmula de inversión:

(10)

$$p_n = f(x_n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-int} f(t) dt.$$

Hemos supuesto que X toma valores $n=0, \pm 1, \pm 2, \dots$ por cuanto basándonos al cambio $Y = \frac{X-a}{b}$ podemos convertirla en una variable de las características.

Demostración.- Sabemos que

$$f(t) = \sum_n e^{itx_n} p_n$$

tomando n' entero, $n' \neq n$,

$$e^{-int} \cdot f(t) = \sum_n e^{it(n-n')} p_n = \sum_{n \neq n'} e^{it(n-n')} p_n + p_{n'}$$

integrando en el intervalo $[-\pi, \pi]$,

$$\int_{-\pi}^{\pi} e^{-int} f(t) dt = \int_{-\pi}^{\pi} \left[\sum_{n \neq n'} e^{it(n-n')} p_n + p_{n'} \right] dt = \sum_{n \neq n'} \left[\int_{-\pi}^{\pi} e^{it(n-n')} p_n dt \right] + 2\pi p_{n'}$$

como visto permitimos al sumatorio en la integral por el teorema de la convergencia absoluta.

$$\text{Pero } \int_{-\pi}^{\pi} e^{it(n-n')} dt = \left[\frac{e^{it(n-n')}}{i(n-n')} \right]_{-\pi}^{\pi} = \frac{\cos(n-n')\pi + i \sin(n-n')\pi - \cos(n-n')(-\pi) - i \sin(n-n')(-\pi)}{i(n-n')} = \frac{2 \sin(n-n')\pi}{n-n'} = 0$$

por tanto

$$\int_{-\pi}^{\pi} e^{-int} f(t) dt = 2\pi p_{n'}.$$

DESARROLLO EN SERIE DE POTENCIAS DE LA FUNCIÓN CARACTERÍSTICA

Ya hemos comprobado en otro punto de este capítulo que si $E(X^k)$ existe, entonces

$$f^{(k)}(0) = i^k \cdot E(X^k), \quad k \leq n.$$

Aplicando la fórmula de Taylor podemos escribir

$$f(t) = \sum_{k=0}^{n-1} \frac{(it)^k}{k!} E(X^k) + \frac{f^{(n)}(t_1)}{n!} t^n, \quad \text{con } t_1 \leq t$$

Si X es una variable aleatoria que posee momentos de cualquier orden, entonces $\varphi(t)$ genera una serie de Taylor que converge a $\varphi(t)$ siempre que el resto tienda a cero a medida que aumenta n , es decir

$$\varphi(t) = \sum_{n=0}^{\infty} \frac{(it)^n \cdot E(X^n)}{n!}, \quad t \in A$$

donde $A = \{t \in \mathbb{R}; \lim_{n \rightarrow \infty} \frac{t^n \cdot \varphi^{(n)}(t)}{n!} = 0, \text{ con } |t| < |t_1|\}$

obvio, teniendo en cuenta el valor de $\varphi^{(n)}(t)$ podemos también caracterizar A , eligiendo a sus elementos que verifiquen $\lim_{n \rightarrow \infty} \frac{|t|^n \cdot E(X^n)}{n!} = 0$.

FUNCION GENERATRIZ DE MOMENTOS

La función generatriz de momentos de una variable aleatoria X se define mediante

$$M(s) = E(e^{sX}) = \int_{\mathbb{R}} e^{sx} dP = \int_{\mathbb{R}} e^{sx} dP$$

para todos aquellos valores de s para los que la correspondiente esperanza existe. Como ya sabemos, si la v.a. X es del tipo discreto, entonces

$$M(s) = \sum_{x \in A} e^{sx} P(X=x), \quad \text{A tal que } P(X \in A) = 1.$$

mientras que para X v.a. continua, tenemos

$$M(s) = \int_{\mathbb{R}} e^{sx} f(x) dx.$$

Esta función se conoce en análisis como la transformada de Laplace de P' (o si se prefiere de F).

Respecto de la existencia de $M(s)$ observamos que $\int_{\mathbb{R}} e^{sx} dP$ es finita para $s \leq 0$ y si es finita para algún s positivo, también lo será para todos s menores que aquel. Esto, junto con consideraciones análogas hechas respecto de la semirrecta real negativa, permite afirmar que $M(s)$ existe, o está definida, en algún intervalo que contenga a 0. Si X es no negativa este intervalo contiene a $[-\infty, 0]$ y puede que parte de $[0, +\infty[$, mientras que si X es no positiva entonces el intervalo contiene a $[0, +\infty[$ y puede que parte de $]-\infty, 0]$. Hay situaciones, no obstante, en las que el intervalo contiene sólo el punto 0. Por ejemplo, una v.a. que tome los valores $\pm n$, $n=1, 2, \dots$ con probabilidad $P(X=n) = P(X=-n) = \frac{1}{n^2}$.

En cualquier caso la existencia de $M(s)$ en un intervalo simétrico da lugar a una serie de importantes propiedades que enunciaremos a continuación por medio del siguiente teorema.

TEOREMA. - Si $M(s)$ está definida en el intervalo $[-s_0, s_0]$, $s_0 > 0$, entonces la variable aleatoria X posee momentos de cualquier orden y además $M^{(k)}(0) = E(X^k)$ (aquí el nombre de función generatriz de momentos que recibe $M(s)$).

Demostración. - Si $M(s)$ está definida en $[-s_0, s_0]$, ello supone que e^{sx} es integrable para $|s| \leq s_0$. Por otra parte

$$e^{1sx} \leq e^{sx} + e^{-sx}$$

y por tanto para $|s| \leq s_0$, e^{1sx} es integrable. Observemos además que, $\forall k$

$$|x|^k \text{ es de menor orden que } e^{1sx}, \text{ cuando } x \rightarrow \pm \infty, \text{ si } s \text{ es fijo } > 0,$$

ello supone que X posee momentos de cualquier orden.

Repasemos ahora en la serie $e^{sx} = \sum_{k=0}^{\infty} \frac{s^k x^k}{k!}$, sus sumas parciales están

mayoradas por la serie

$$e^{1sx} = \sum_{k=0}^{\infty} \frac{|s x|^k}{k!} \quad (\text{en ambos casos } |s| \leq s_0)$$

y no dudamos que e^{1sx} es una función integrable, por lo tanto aplicamos el teorema de la convergencia dominada y recibimos

$$E(e^{sx}) = M(s) = \sum_{k=0}^{\infty} \frac{E(X^k)}{k!} s^k, \quad |s| \leq s_0.$$

Resulta pues que $M(s)$ posee un desarrollo en serie de Taylor alrededor del punto 0, y de acuerdo con las propiedades de dicho desarrollo los coeficientes son las derivadas de la función en el pt 0, es decir

$$M^{(k)}(0) = E(X^k).$$

COROLARIO. - Si $M(s)$ está definida en $|s| \leq s_0$ y de alguna manera podemos obtener un desarrollo en serie de potencias de $M(s)$, de la forma

$$M(s) = \sum_{k=0}^{\infty} a_k s^k, \quad |s| \leq s_0.$$

de acuerdo con la unicidad del desarrollo en serie en el campo de convergencia de la serie, tendremos que

$$a_k = \frac{M^{(k)}(0)}{k!}.$$

pero como $M^{(k)}(0) = E(X^k)$, etc nos permite obtener los momentos de X , mediante

$$E(X^k) = a_k \cdot k!.$$

Relación entre la función generatriz y la función característica. - Cuando la función generatriz de momentos existe, sabemos que

$$\varphi(t) = E(e^{itx})$$

$$M(t) = E(e^{tx})$$

y por tanto

$$\varphi(t) = M(it)$$

Esta relación impone que muchas de las propiedades estudiadas para la función característica sean aplicables a la función generatriz, no obstante, una de las más importantes, la existencia, siempre de la función característica, ya hemos visto que no es siempre verificada por $M(s)$. Este método es más que suficiente para que la función generatriz quede en pura anécdota y sea la característica la que, utilizada en función de la propiedad, resuelve todos los problemas de interés y de unicidad.

Observamos finalmente que

$$\varphi(t) = \sum_{k \geq 0} \frac{(it)^k}{k!} E(X^k)$$

está mayorada por

$$\sum_{k \geq 0} \frac{|t|^k}{k!} E(|X|^k) = E(e^{|tX|})$$

y hemos dicho que si $M(t)$ está definida en $|t| \leq t_0$, entonces $e^{|tX|}$ es integrable, por tanto $\varphi(t)$ se desarrolla en serie de Taylor ni la correspondiente función generatriz de momentos existe.

(13) FUNCIÓN CARACTERÍSTICA DE UN VECTOR ALEATORIO

Sea $\vec{X}$ un vector aleatorio de componentes $(X_1, X_2, \dots, X_n)$, se define la función característica del vector como la esperanza de la variable $e^{i(t_1 X_1 + t_2 X_2 + \dots + t_n X_n)}$. Es decir

$$\varphi_{\vec{X}}(t_1, t_2, \dots, t_n) = E\left(\exp\left[i \sum_{k=1}^n t_k X_k\right]\right), \quad t_k \in \mathbb{R}.$$

De acuerdo con esta definición, generalización inmediata de la dada para variables aleatorias, la función característica del vector $\vec{X}$ existe siempre y goza además de las siguientes propiedades.

PROPIEDADES DE LA F.C. DE UN VECTOR ALEATORIO

1.- $\varphi_{\vec{X}}(0, \dots, 0) = 1$

2.- $|\varphi_{\vec{X}}(t_1, \dots, t_n)| \leq 1$

3.- $\varphi_{\vec{X}}(t_1, \dots, t_n)$ es uniformemente continua en $\mathbb{R}^n$.

4.- Si la función característica de $\vec{X}$ es $\varphi_{\vec{X}}(t_1, \dots, t_n)$, la del vector $\vec{Y}$, cuyas componentes se definen $Y_k = a_k X_k + b_k$, es

$$\varphi_{\vec{Y}}(t_1, \dots, t_n) = \exp\left(i \sum_{k=1}^n t_k b_k\right) \cdot \varphi_{\vec{X}}(a_1 t_1, \dots, a_n t_n).$$

5.- Si el momento conjunto de orden $(n_1, \dots, n_n)$ existe, entonces

$$\frac{\partial^{n_1 + \dots + n_n}}{\partial t_1^{n_1} \dots \partial t_n^{n_n}} \varphi_{\vec{X}}(t_1, \dots, t_n) \Big|_{t_1 = \dots = t_n = 0} = i^{n_1 + \dots + n_n} E(X_1^{n_1} \dots X_n^{n_n})$$

En particular

$$\frac{\partial^r}{\partial t_k^r} \varphi_{\vec{X}}(t_1, \dots, t_n) \Big|_{t_1 = \dots = t_n = 0} = i^r E(X_k^r), \quad k=1, \dots, n$$

6.- La función característica de cualquier subvector de dimensión m , $\vec{X}_1$, se obtiene a partir de la de $\vec{X}$ sin más que igualar a cero las t_k del subvector complementario, $\vec{X}_2$, de dimensión $n-m$. Así

$$\varphi_{\vec{X}_1}(t_1, \dots, t_m) = \varphi_{\vec{X}}(t_1, \dots, t_m, 0, \dots, 0)$$

En particular, la función característica de cada componente se obtiene mediante

$$\varphi_{X_k}(t_k) = \varphi_{\vec{X}}(0, \dots, 0, t_k, 0, \dots, 0).$$

(14)

Todas estas propiedades tienen una demostración análoga, si bien ligeramente más complicada, a la de sus correspondientes versiones unidimensionales. (15)

La función característica del vector $\vec{X}$ permite obtener fácilmente la función característica de la suma de sus componentes. De efecto

TEOREMA - Si el vector aleatorio $\vec{X}$ tiene por función característica $\varphi_{\vec{X}}(t_1, \dots, t_n)$, entonces la variable aleatoria $X_1 + X_2 + \dots + X_n$ tiene por función característica $\varphi(t_1, t_1, \dots, t_1)$.

Demstración - Sea $Y = \sum_{k=1}^n X_k$, de acuerdo con la definición de función característica, tendremos

$$\varphi_Y(t) = E(e^{itY}) = E\left(\exp\left[i t \sum_{k=1}^n X_k\right]\right) = E\left(\exp\left[i \sum_{k=1}^n t X_k\right]\right)$$

pero

$$\varphi_{\vec{X}}(t_1, \dots, t_n) = E\left(\exp\left[i \sum_{k=1}^n t_k X_k\right]\right)$$

que para $t_k = t$, $k=1, \dots, n$ da lugar a $\varphi_Y(t)$.

Finalmente mencionamos, sin demostración por cuanto nuevamente sta es análoga a la correspondiente unidimensional, las versiones técnicas de la fórmula de inversión y del teorema de unicidad.

Fórmula de inversión - Sea $\vec{X}$ un vector aleatorio con función característica $\varphi_{\vec{X}}(t_1, \dots, t_n)$, entonces

$$P\left\{a_k \leq X_k \leq b_k, k=1, 2, \dots, n\right\} = \lim_{T \rightarrow \infty} \frac{1}{(2\pi)^n} \int_{-T}^T \dots \int_{-T}^T \prod_{k=1}^n \frac{e^{-it_k a_k} - e^{-it_k b_k}}{it_k} \varphi_{\vec{X}}(t_1, \dots, t_n) dt_1 \dots dt_n$$

o bien su equivalente

$$P\left\{a_k + h < X_k \leq a_k + h, k=1, 2, \dots, n\right\} = \lim_{T \rightarrow \infty} \frac{1}{(2\pi)^n} \int_{-T}^T \dots \int_{-T}^T \prod_{k=1}^n \frac{e^{it_k h} - 1}{it_k} e^{-it_k a_k} \varphi_{\vec{X}}(t_1, \dots, t_n) dt_1 \dots dt_n$$

donde a_k y b_k son números reales que satisfacen la siguiente condición:

La probabilidad de tomar valores en la superficie del paralelepípedo $\{a_k < X_k \leq b_k, k=1, \dots, n\}$ es igual a 0.

COROLARIO - Si la función característica es absolutamente integrable, entonces el vector aleatorio es continuo y su función de densidad conjunta se puede obtener a partir de

$$f_{\vec{X}}(x_1, \dots, x_n) = \frac{1}{(2\pi)^n} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} e^{-i \sum_{k=1}^n t_k x_k} \varphi_{\vec{X}}(t_1, \dots, t_n) dt_1 \dots dt_n.$$

Ente, al igual que para las variables aleatorias, otra versión de la fórmula de inversión que permite obtener fácilmente las funciones de cuantía para vectores aleatorios del tipo descrito:

OTRA FORMA DE LA FÓRMULA DE INVERSIÓN - Sea $\varphi_{\vec{X}}(t_1, \dots, t_n)$ la función característica de un vector aleatorio $\vec{X}$, entonces (16)

$$P(X_1 = x_1, \dots, X_n = x_n) = \lim_{T \rightarrow \infty} \frac{1}{(2\pi)^n} \int_{-T}^T \dots \int_{-T}^T e^{-i \sum_{k=1}^n t_k x_k} \varphi_{\vec{X}}(t_1, \dots, t_n) dt_1 \dots dt_n.$$

Basado en la fórmula de inversión puede deducirse, también ahora, el siguiente teorema de unicidad.

TEOREMA DE UNICIDAD - Existe una correspondencia biunívoca entre las funciones características y de distribución de un vector aleatorio.

Para finalizar el capítulo mencionamos que también podría hallarse ahora el desarrollo en serie de potencias de la función característica de un vector aleatorio. Basado que se basa en la fórmula de Taylor para variables n -dimensionales.

Igualmente existe el concepto de función generatriz de momentos para un vector aleatorio $\vec{X}$, cuya definición es análoga a la correspondiente versión unidimensional. Igualmente son de las propiedades de φ derivadas para tal concepto el caso de variables aleatorias, modificadas adecuadamente para su versión vectorial.

EJEMPLOS

Función característica de algunas distribuciones de probabilidad.

1) BINOMIAL.

Sea X una v.a. con distribución de probabilidad $B(n, p)$, entonces

$$\varphi(t) = \sum_{x=0}^n e^{itx} \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n \binom{n}{x} (pe^{it})^x q^{n-x} = (pe^{it} + q)^n$$

de acuerdo con la relación $M(t) = \varphi(t)$, entonces en aquellos t puntos que existe,

$$M(t) = (pe^{it} + q)^n.$$

Se comprueba que $M(t)$ existe para todo t .

Por otra parte

$$\frac{d}{dt} \varphi(t) = n(pe^{it} + q)^{n-1} \cdot ipe^{it} \quad \text{y} \quad \left. \frac{d}{dt} \varphi(t) \right|_{t=0} = inp = iE(X).$$

La función $\psi(t) = \log \varphi(t) = n \log(pe^{it} + q)$ obtenida

$$\psi'(t) = \frac{inp e^{it}}{pe^{it} + q} \rightarrow \psi'(0) = inp = iE(X)$$

$$\psi''(t) = \frac{i^2 np e^{it} (pe^{it} + q) - i^2 np^2 e^{2it}}{(pe^{it} + q)^2} \rightarrow \psi''(0) = \frac{-npq}{1} = -npq = -\text{var}(X).$$

2) POISSON.

Para una v.a. Poisson, $P(\lambda)$, su función característica vale

$$\varphi(t) = \sum_{x \geq 0} e^{itx} \frac{\lambda^x}{x!} e^{-\lambda} = e^{-\lambda} \sum_{x \geq 0} \frac{(\lambda e^{it})^x}{x!} = e^{-\lambda} \cdot e^{\lambda e^{it}} = e^{\lambda(e^{it} - 1)}$$

3) MULTINOMIAL.

Si el vector $\vec{X}$ posee una distribución multinomial con parámetros $n; p_1, p_2, \dots, p_k$, su función característica vale

$$\begin{aligned} \varphi_{\vec{X}}(t_1, \dots, t_k) &= \sum_{x_1, \dots, x_k} e^{i \sum_{j=1}^k t_j x_j} \frac{n!}{x_1! \dots x_k!} p_1^{x_1} \dots p_k^{x_k} = \\ &= \sum_{x_1, \dots, x_k} \frac{n!}{x_1! \dots x_k!} (p_1 e^{it_1})^{x_1} \dots (p_k e^{it_k})^{x_k} = (p_1 e^{it_1} + \dots + p_k e^{it_k})^n \end{aligned}$$

$$\frac{\partial^k}{\partial t_1 \dots \partial t_k} \varphi_{\vec{X}}(t_1, \dots, t_k) \Big|_{t_1=t_2=\dots=t_k=0} = n(n-1) \dots (n-k+1) i^k p_1 \dots p_k (p_1 e^{it_1} + \dots + p_k e^{it_k})^{n-k} =$$

$$= n(n-1) \dots (n-k+1) i^k p_1 \dots p_k$$

de lo que

$$E(\vec{X}_1, \dots, \vec{X}_k) = n(n-1) \dots (n-k+1) p_1 p_2 \dots p_k$$

Obsérvese que la función característica de la componente $\vec{X}_j$ podemos obtenerla mediante

$$\begin{aligned} \varphi_{\vec{X}_j}(t_j) &= \varphi_{\vec{X}}(0, \dots, 0, t_j, 0, \dots, 0) = (p_1 + p_2 + \dots + p_j e^{it_j} + \dots + p_k)^n = \\ &= (p_j e^{it_j} + \sum_{i \neq j} p_i)^n = (p_j e^{it_j} + (1 - p_j))^n = (p_j e^{it_j} + q_j)^n \end{aligned}$$

y por el teorema de unicidad $\vec{X}_j$ es una $B(n, p_j)$, como en su momento habíamos obtenido estudiando los marginales de la multinomial.

4) NORMAL.

Supongamos que $\vec{X}$ es una variable aleatoria $N(0, 1)$, su función característica vale

$$\begin{aligned} \varphi(t) &= \int_{\mathbb{R}} e^{itx} f(x) dx = \int_{\mathbb{R}} e^{itx} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{itx - x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{(2itx - x^2 + t^2)/2} \cdot e^{-t^2/2} dx \\ &= \frac{1}{\sqrt{2\pi}} e^{-t^2/2} \int_{\mathbb{R}} e^{-(x-it)^2/2} dx = e^{-t^2/2} \end{aligned}$$

(17)

Para obtener la función característica de una v.a. $\vec{X}$, $N(\mu, \sigma^2)$, podemos utilizar la propiedad

$$\varphi_{a\vec{X}+b}(t) = e^{ibt} \varphi_{\vec{X}}(at)$$

puesto que si $\vec{X}$ es $N(\mu, \sigma^2)$, la variable $\vec{Z} = \frac{\vec{X} - \mu}{\sigma}$ es $N(0, 1)$ es por tanto

$$\varphi_{\vec{X}}(t) = \varphi_{\sigma\vec{Z}+\mu}(t) = e^{it\mu} \varphi_{\vec{Z}}(\sigma t) = e^{it\mu} \cdot e^{-t^2\sigma^2/2} = e^{it\mu - t^2\sigma^2/2}$$

Podríamos haber obtenido este resultado por otro camino. En efecto, sabemos que si $\vec{X}$ es $N(0, 1)$, entonces

$$E(\vec{X}^{2n+1}) = 0 \quad , \quad E(\vec{X}^{2n}) = \frac{(2n)!}{2^n \cdot n!}$$

además que $\varphi(t)$ admite un desarrollo en serie, puesto que existen todos los momentos, para todos aquellos t que verifican

$$\lim_{n \rightarrow \infty} \frac{|t|^{2n} \cdot E(\vec{X}^{2n})}{n!} = 0$$

pero

$$\lim_{n \rightarrow \infty} \frac{|t|^{2n} \cdot E(\vec{X}^{2n})}{(2n)!} = \lim_{n \rightarrow \infty} \frac{|t|^{2n} \cdot (2n)!}{(2n)! \cdot 2^n \cdot n!} = \lim_{n \rightarrow \infty} \frac{|t|^{2n}}{2^n \cdot n!} = 0, \quad \forall t$$

luego

$$\begin{aligned} \varphi(t) &= \sum_{k \geq 0} \frac{(it)^{2k} \cdot E(\vec{X}^{2k})}{(2k)!} = \sum_{k \geq 0} \frac{(it)^{2k} \cdot (2k)!}{(2k)! \cdot 2^k \cdot k!} = \sum_{k \geq 0} \left(\frac{-t^2}{2}\right)^k \cdot \frac{1}{k!} = \\ &= e^{-t^2/2} \end{aligned}$$

5) GAMMA.

Si $\vec{X}$ se distribuye como una Gamma con parámetros α, β , entonces

$$\varphi(t) = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^\infty e^{itx} x^{\alpha-1} \cdot e^{-x/\beta} dx = \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^\infty x^{\alpha-1} \cdot e^{-x(1-i\beta t)/\beta} dx$$

haciendo $x(1-i\beta t) = y$, tenemos

$$x = y/(1-i\beta t) \quad , \quad dx = dy/(1-i\beta t) \quad , \quad y \in [0, +\infty[$$

$$\varphi(t) = (1-i\beta t)^{-\alpha} \cdot \frac{1}{\Gamma(\alpha) \beta^\alpha} \int_0^\infty y^{\alpha-1} \cdot e^{-y/\beta} dy = (1-i\beta t)^{-\alpha}$$

(18)

Así, para una χ^2 , en la que $\alpha = 1/2$, $\beta = 2$, tendremos como función característica (19)

$$\varphi_{\chi^2}(t) = (1 - 2it)^{-1/2}.$$

Para una exponencial negativa, $\alpha = 1$, $\beta = 1/\lambda$, tendremos

$$\varphi(t) = \left(1 - \frac{it}{\lambda}\right)^{-1} = \frac{\lambda}{\lambda - it}.$$

6) NORMAL BIVARIANTE

Supongamos que $\vec{X}$ es un vector normal bivalente de manera que sus componentes son $N(0,1)$ cada una de ellas. Su función de densidad conjunta viene dada por

$$f(x,y) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}[x^2 - 2\rho xy + y^2]\right\}$$

la función característica será

$$\varphi_{\vec{X}}(t_1, t_2) = \int_{\mathbb{R}^2} e^{i(t_1x + t_2y)} f(x,y) dx dy = \int_{\mathbb{R}^2} \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{i(t_1x + t_2y) - \frac{x^2 - 2\rho xy + y^2}{2(1-\rho^2)}\right\} dx dy$$

Con un cambio de variables adecuado llegamos a

$$\varphi_{\vec{X}}(t_1, t_2) = \int_{\mathbb{R}^2} e^{-\frac{1}{2}(t_1^2 + 2\rho t_1 t_2 + t_2^2)} \frac{1}{2\pi} e^{-\frac{1}{2}(u^2 + v^2)} du dv = e^{-\frac{1}{2}(t_1^2 + 2\rho t_1 t_2 + t_2^2)}.$$

Si queremos ahora obtener la función característica de un vector $\vec{X}$ normal bivalente completamente general, es decir una función de densidad conjunta dada por

$$f(x,y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right]\right\}$$

Si hacemos las transformaciones $Z_1 = \frac{X-\mu_1}{\sigma_1}$ y $Z_2 = \frac{Y-\mu_2}{\sigma_2}$, las variables conjuntamente, (Z_1, Z_2) dan lugar a un vector aleatorio normal bivalente tipificado, es decir, con función de densidad conjunta independiente, ello supone, de acuerdo con una propiedad de las ~~normales~~ funciones características que

$$\begin{aligned} \varphi_{\vec{X}}(t_1, t_2) &= e^{i(\mu_1 t_1 + \mu_2 t_2)} \cdot \varphi_{\vec{Z}}(\sigma_1 t_1, \sigma_2 t_2) = \\ &= \exp\left\{i\mu_1 t_1 + i\mu_2 t_2 - \frac{1}{2}(\sigma_1^2 t_1^2 + 2\rho\sigma_1\sigma_2 t_1 t_2 + \sigma_2^2 t_2^2)\right\} \end{aligned}$$

Si queremos ahora conocer la función característica de la variable $U = X + Y$, podemos

utilizar una propiedad de las funciones características de los vectores aleatorios que dice

$$\varphi_{\sum_k \vec{X}_k}(t) = \varphi_{\vec{X}}(t, t_1, \dots, t_n)$$

Así pues

$$\begin{aligned} \varphi_U(t) &= \varphi_{\vec{X}}(t, t) = \exp\left\{i(\mu_1 + i\mu_2)t - \frac{1}{2}(\sigma_1^2 + 2\rho\sigma_1\sigma_2 + \sigma_2^2)t^2\right\} = \\ &= \exp\left\{it(\mu_1 + \mu_2) - \frac{1}{2}t^2(\sigma_1^2 + 2\rho\sigma_1\sigma_2 + \sigma_2^2)\right\} \end{aligned}$$

pero esta es la función característica de una normal con esperanza $\mu = \mu_1 + \mu_2$ y con varianza $\sigma^2 = \sigma_1^2 + 2\rho\sigma_1\sigma_2 + \sigma_2^2 = \sigma_1^2 + 2\cos(\theta_1, \theta_2) + \sigma_2^2$. Resulta así que para demostrar la utilidad del teorema de unicidad.

(20)

Capítulo 11

Independencia

INDEPENDENCIA

Sea $(\Omega, \mathcal{A}, P)$ un espacio de probabilidad y sean $\mathcal{A}_j, j=1, \dots, k$ familias de conjuntos tales que $\mathcal{A}_j \subset \mathcal{A}, j=1, \dots, k$.

DEFINICION 1.- Decimos que las familias $\mathcal{A}_j$ son independientes, si para cada $A_j \in \mathcal{A}_j, j=1, \dots, k$ los sucesos $A_1, \dots, A_k$ son independientes. Es decir

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_n}) = \prod_{j=1}^n P(A_{i_j}) \quad \text{donde } (i_1, \dots, i_n) \subset (1, \dots, k).$$

De esta definición se desprende de inmediato que las subfamilias de familias independientes son también independientes.

INDEPENDENCIA DE VARIABLES ALEATORIAS

Sea X una v.a. definida sobre $(\Omega, \mathcal{A}, P)$. Sea β la tribu de $\mathcal{B}$, la familia de conjuntos de $\mathcal{B}$, $X^{-1}(\beta)$ es también una σ -álgebra como fácilmente puede comprobarse. A esta σ -álgebra la llamamos como la σ -álgebra inducida por X . Consideremos ahora un conjunto de variables aleatorias $X_j, j=1, \dots, k$ definidas todas ellas sobre el espacio de probabilidad $(\Omega, \mathcal{A}, P)$ y sean $\mathcal{A}_j$ las σ -álgebras inducidas por dichas variables.

DEFINICION 2.- Decimos que las variables aleatorias $X_j, j=1, \dots, k$ son independientes si los σ -álgebras que inducen lo son.

Teniendo en cuenta la definición de la σ -álgebra inducida, $\forall A_j \in \mathcal{A}_j, \exists B_j \in \beta / A_j = X_j^{-1}(B_j)$ entonces

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_n}) = \prod_{j=1}^n P(A_{i_j}) \quad (i_1, \dots, i_n) \subset (1, \dots, k) \quad (1)$$

pero

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_n}) = P(X_{i_1} \in B_{i_1}, \dots, X_{i_n} \in B_{i_n}) = \prod_{j=1}^n P(X_{i_j} \in B_{i_j}).$$

Como los $A_j \in \mathcal{A}_j, j=1, \dots, k$ están definidos como imágenes de conjuntos de $\mathcal{B}$, esto supone que se verificase la última de las desigualdades suita, verificamos la anterior (1). En definitiva, esta definición para la independencia de las variables aleatorias en términos de conjunto de $\mathcal{B}$, puede ser esta

DEFINICION 3.- Las variables aleatorias $X_j, j=1, \dots, k$ son independientes si

$$P(X_j \in B_j, j=1, \dots, n) = \prod_{j=1}^n P(X_j \in B_j), \quad (i_1, \dots, i_n) \subset (1, \dots, k)$$

cualquiera que sean los conjuntos de $\mathcal{B}$ B_j .

Los variables aleatorias que no son independientes se dice que son dependientes.

①

Antes de demostrar el teorema de factorización, el más importante de este capítulo, vamos algunos lemas, pero que nos serán de utilidad.

②

LEMA 1.- Sean $X_j, j=1, \dots, k$ variables aleatorias independientes y sean $g_j: (R, \beta) \rightarrow (R, \beta)$ funciones medibles, de manera que $g_j(X_j)$ es una variable aleatoria. Entonces las variables aleatorias $g_j(X_j), j=1, \dots, k$ son también independientes.

Demostración.- Sea X una v.a. y sea g una función medible. Denotemos por $\mathcal{A}_X$ y $\mathcal{A}_{g(X)}$ los σ -álgebras inducidos por las v.a. X y $g(X)$. Sea $A \in \mathcal{A}_{g(X)}$, entonces $\exists B \in \beta$, tal que $[g(X)]^{-1}(B) = A$. Pero

$$A = [g(X)]^{-1}(B) = X^{-1}[g^{-1}(B)] = X^{-1}(B')$$

donde $B' = g^{-1}(B)$ y como g es medible $B' \in \beta$ y por tanto $X^{-1}(B') = A \in \mathcal{A}_X$, es decir $\mathcal{A}_{g(X)} \subset \mathcal{A}_X$.

De acuerdo con esto, para cada $j=1, \dots, k$, tenemos

$$\mathcal{A}_{g_j(X_j)} \subset \mathcal{A}_{X_j}$$

y como la familia $\mathcal{A}_{X_j}, j=1, \dots, k$ es independiente lo es cualquier familia de subfamilias y $\mathcal{A}_{g_j(X_j)}, j=1, \dots, k$ constituyen un conjunto de v.a. independientes.

LEMA 2.- Una condición necesaria y suficiente para que las variables aleatorias $X_j, j=1, \dots, k$ sean independientes es que los conjuntos $\mathcal{E}_j, j=1, \dots, k$, con

$$\mathcal{E}_j = \{X_j^{-1}[I_{[a, x]}], x \in R\}$$

sean independientes.

Demostración.- Directa.- Si las v.a. son independientes, la familia $\mathcal{A}_j = X_j^{-1}(\beta), \beta \in \beta$ son independientes y por tanto también lo serán las subfamilias de ellas y los $\mathcal{E}_j$ son subfamilias de los $\mathcal{A}_j$.

Inversa.- Para cada $\mathcal{E}_j$ definimos

$$\mathcal{E}_j^* = \{ \text{menor clase de conjunto estable para los sucesos numerables y diferencias propias, que contiene a } \mathcal{E}_j \}.$$

Los $\mathcal{E}_j^*$, así definidos también son independientes, llamémoslo. Definamos

$$\mathcal{D}_i = \{ D_i \in \mathcal{A}; P(D_i \cap \bigcap_{j=1}^k A_j) = P(D_i) \cdot \prod_{j=1}^k P(A_j), A_j \in \mathcal{E}_j \}$$

este clase de conjuntos verifica las siguientes propiedades:

a) $\mathcal{E}_i \subset \mathcal{D}_i$

$$\forall A_i \in \mathcal{C}_i, P(A_i \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j) = P(A_i) \cdot \prod_{\substack{j=1 \\ j \neq i}}^k P(A_j), A_j \in \mathcal{C}_j$$

por lo que $\mathcal{C}_j$ son independientes.

b) Sean $\{D_n\}_{n \geq 1}, D_n \in \mathcal{D}_i, \forall n$ y $D_m \cap D_n = \emptyset, m \neq n$. Entonces

$$\bigcup_{n \geq 1} D_n \in \mathcal{D}_i.$$

$$\begin{aligned} P\left(\bigcup_{n \geq 1} D_n \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j\right) &= \sum_{n \geq 1} P(D_n \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j) = \prod_{\substack{j=1 \\ j \neq i}}^k P(A_j) \left[\sum_{n \geq 1} P(D_n) \right] = \\ &= P\left(\bigcup_{n \geq 1} D_n\right) \cdot \prod_{\substack{j=1 \\ j \neq i}}^k P(A_j), A_j \in \mathcal{C}_j. \end{aligned}$$

c) $D_1, D_2 \in \mathcal{D}_i$, con $D_2 \subset D_1$, entonces $D_1 - D_2 \in \mathcal{D}_i$.

$$(D_1 - D_2) \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j = D_1 \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j - D_2 \cap \bigcap_{\substack{j=1 \\ j \neq i}}^k A_j, A_j \in \mathcal{C}_j$$

y de aquí el resultado.

Dados las propiedades que define $\mathcal{D}_j$ y los hechos de estar definida $\mathcal{C}_j^*$ como "la menor σ -álgebra..." entonces $\mathcal{C}_j^* \subset \mathcal{D}_j$. Además, por definición de $\mathcal{D}_i$, las familias

$$\{\mathcal{D}_i, \mathcal{C}_j, j=1, \dots, k, j \neq i\}$$

son independientes, en particular como $\mathcal{C}_j^* \subset \mathcal{D}_j$, tenemos que las familias

$$\{\mathcal{C}_i^*, \mathcal{C}_j, j=1, \dots, k, j \neq i\}$$

son independientes. Repitiendo el razonamiento y utilizando en cada ocasión una de las $\mathcal{C}_j$ por un independiente $\mathcal{D}_j$ llegamos a la conclusión de que las familias

$$\{\mathcal{D}_j, j=1, \dots, k\}$$

son como las familias

$$\{\mathcal{C}_j^*, j=1, \dots, k\}$$

son independientes. Pero las $\mathcal{C}_j^*$ gozan de otra importante propiedad. En efecto, al ser las $\mathcal{C}_j$ σ -álgebras para intersección finita, tenemos que $\mathcal{C}_j^* = \mathcal{D}_j = \mathcal{S}_j^*(\emptyset), 0 < \beta$. Recordemos:

Sea $\mathcal{C}_j^* = \{C' \in \mathcal{C}_j^*; C' \cap B \in \mathcal{C}_j^*, \forall B \in \mathcal{C}_j^*\}$

$$1) C'_1, C'_2 \in \mathcal{C}_j^*, C'_1 \cap C'_2 \rightarrow C'_1 \cap C'_2 \in \mathcal{C}_j^*$$

$$\forall B \in \mathcal{C}_j^*; (C'_1 - C'_2) \cap B = C'_1 \cap B - C'_2 \cap B \in \mathcal{C}_j^*$$

(3)

$$2) \{C'_n\}_{n \geq 1} \subset \mathcal{C}_j^*, C'_n \cap C'_m = \emptyset, m \neq n \rightarrow \bigcup_{n \geq 1} C'_n \in \mathcal{C}_j^*$$

(4)

$$\forall B \in \mathcal{C}_j^*, (\bigcup_{n \geq 1} C'_n) \cap B = \bigcup_{n \geq 1} (C'_n \cap B) \in \mathcal{C}_j^*$$

Resulta pues que $\mathcal{C}_j^*$ es σ -álgebra para las mismas operaciones que lo es $\mathcal{C}_j$, además $\forall C \in \mathcal{C}_j, C \cap B \in \mathcal{C}_j^* \subset \mathcal{C}_j^*, B \in \mathcal{C}_j$, tendremos pues que $\mathcal{C}_j \subset \mathcal{C}_j^*$ y por ser $\mathcal{C}_j^*$ mínima, tendremos $\mathcal{C}_j^* \supset \mathcal{C}_j$, pero por definición $\mathcal{C}_j^* \supset \mathcal{C}_j$, en definitiva $\mathcal{C}_j^* \equiv \mathcal{C}_j$.

Sea ahora $\mathcal{C}_j^* = \{C \in \mathcal{C}_j^*; C \cap B \in \mathcal{C}_j^*, \forall B \in \mathcal{C}_j^*\}$. De igual manera se comprueba que esta misma σ -álgebra es σ -álgebra para las mismas operaciones que lo es $\mathcal{C}_j^*$. Además, $\forall C \in \mathcal{C}_j, C \cap B \in \mathcal{C}_j^*, \forall B \in \mathcal{C}_j^*$ ya que $\mathcal{C}_j^* \equiv \mathcal{C}_j$, en definitiva $\mathcal{C}_j \subset \mathcal{C}_j^*$ y razonando como antes llegamos a $\mathcal{C}_j^* \equiv \mathcal{C}_j$, a decir que $\mathcal{C}_j^*$ es σ -álgebra para la intersección finita y siendo además σ -álgebra para las diferencias finitas y los uniones numerables, tendremos que es un σ -álgebra que necesariamente debe de coincidir con $\mathcal{D}_j = \mathcal{S}_j^*(\emptyset), 0 < \beta$ (se comprueba por este método).

En definitiva las familias

$$\{\mathcal{C}_j^*, j=1, \dots, k\} \equiv \{\mathcal{D}_j = \mathcal{S}_j^*(\emptyset), 0 < \beta, j=1, \dots, k\}$$

son independientes, lo que supone que las variables aleatorias $\mathcal{S}_j^*, j=1, \dots, k$, lo son.

Observación. - La demostración se ha llevado a cabo haciendo abstracción del contenido de las familias $\mathcal{C}_j$.

Ello supone que tiene validez general y que en realidad hemos demostrado este teorema, de una manera más general.

TEOREMA. - Los σ -álgebras engendrados por familias $\mathcal{C}_j$, independientes y σ -álgebras para la $\cap$ finita, son también independientes.

Consideremos ahora las funciones de distribución y de densidad conjuntas del vector aleatorio que las k v.a. $X_1, \dots, X_k$ constituyen. El teorema que a continuación demostramos establece un criterio de independencia para dichos variables basado en las citadas funciones. Constituye este teorema, sin duda, el resultado más interesante de este capítulo.

TEOREMA DE FACTORIZACIÓN. - Sean $F_{\mathbb{R}}^k(x_1, \dots, x_k)$ y $f_{\mathbb{R}}^k(x_1, \dots, x_k)$ las funciones de distribución y densidad o cuantía conjuntas del vector aleatorio $\mathbb{R}^k = (X_1, \dots, X_k)$. Sean $F_j(x_j)$ y $f_j(x_j), j=1, \dots, k$ las correspondientes marginales. Las v.a. $X_j, j=1, \dots, k$ son independientes si y sólo si se verifica alguna de las dos condiciones (equivalentes) siguientes:

$$1) F_{\mathbb{R}}^k(x_1, \dots, x_k) = \prod_{j=1}^k F_j(x_j), x_j \in \mathbb{R}, j=1, \dots, k$$

$$2) f_{\vec{x}}(x_1, \dots, x_k) = \prod_{j=1}^k f_j(x_j), \quad x_j \in \mathbb{R}, \quad j=1, \dots, k$$

(5)

Demostración.-

1) Si las v.a. son independientes, sabemos que

$$P(\vec{x}_j \in B_j, j=1, \dots, k) = \prod_{j=1}^k P(\vec{x}_j \in B_j), \quad B_j \in \mathcal{B}$$

tomando $B_j =]-\infty, x_j]$, tenemos

$$P(\vec{x}_j \in]-\infty, x_j], j=1, \dots, k) = F_{\vec{x}}(x_1, \dots, x_k) = \prod_{j=1}^k F_j(x_j), \quad x_j \in \mathbb{R}$$

El inverso se verifica tan sólo que utilizar el lema 2.

2) Distinguiremos el caso continuo del discreto a la hora de la demostración.

2.a) Caso discreto.

Sea $A \subset \mathbb{R}^k$ tal que $P(\vec{x} \in A) = 1$. Sea $\vec{x} = (x_1, \dots, x_k) \in A$, entonces

$$f_{\vec{x}}(x_1, \dots, x_k) = P(\vec{x}_j = x_j, j=1, \dots, k)$$

y siendo independientes sabemos que

$$P(\vec{x}_j = x_j, j=1, \dots, k) = \prod_{j=1}^k P(\vec{x}_j = x_j) = \prod_{j=1}^k f_j(x_j), \quad x_j \in A_j$$

Para cualquier $\vec{x} \in \mathbb{R}^k - A$, la igualdad es trivialmente cierta por cuanto es igual a cero en ambos lados.

Para demostrar el inverso, sea $B_j =]-\infty, x_j]$, $x_j \in \mathbb{R}$, $j=1, \dots, k$

y sea $B = B_1 \times B_2 \times \dots \times B_k$, tenemos

$$P(\vec{x} \in B) = P(\vec{x}_j \in B_j, j=1, \dots, k) = F_{\vec{x}}(x_1, \dots, x_k) =$$

$$= \int_{\vec{x} \in B} f_{\vec{x}}(x_1, \dots, x_k) = \int_{\vec{x} \in B} f_1(x_1) \dots f_k(x_k) = \sum_{(x_1, \dots, x_k) \in B} f_1(x_1) \dots f_k(x_k) =$$

$$= \prod_{j=1}^k \left[\sum_{x_j \in B_j} f_j(x_j) \right] = \prod_{j=1}^k F_j(x_j)$$

y por 1), las variables aleatorias son independientes.

2.b) Caso continuo

(6)

Si hay independencia entre las variables aleatorias, tenemos

$$F_{\vec{x}}(x_1, \dots, x_k) = \prod_{j=1}^k F_j(x_j)$$

derivando parcialmente en ambos miembros llegamos a

$$f_{\vec{x}}(x_1, \dots, x_k) = \prod_{j=1}^k f_j(x_j)$$

El punto $(x_1, \dots, x_k)$ debe sufrir un punto de continuidad de la función de densidad. En cualquier caso, sabemos que para los rectángulos aleatorios de tipo continuo el número de puntos de discontinuidad tiene medida nula y por tanto no afecta al resultado.

Para el inverso, sea

$$f_{\vec{x}}(x_1, \dots, x_k) = \prod_{j=1}^k f_j(x_j)$$

sea $G_j =]-\infty, y_j]$, $y_j \in \mathbb{R}$, $j=1, \dots, k$ entonces

$$F_{\vec{x}}(y_1, \dots, y_k) = \int_{\vec{x} \in G} f_{\vec{x}}(x_1, \dots, x_k) dx_1 \dots dx_k = \int_{\prod_{j=1}^k G_j} \prod_{j=1}^k f_j(x_j) dx_1 \dots dx_k = \prod_{j=1}^k F_j(y_j)$$

El lema de factorización es también aplicable a las funciones características, pero necesitamos previamente estudiar la estructura del producto de variables aleatorias cuando son independientes.

LEMA 3. - Sean X_j , $j=1, \dots, k$ v.a. y sean $g_j: (\mathbb{R}, \mathcal{B}) \rightarrow (\mathbb{R}, \mathcal{B})$ transformaciones medibles, $j=1, \dots, k$

Si las variables aleatorias X_j , $j=1, \dots, k$ son independientes, entonces

$$E \left[\prod_{j=1}^k g_j(X_j) \right] = \prod_{j=1}^k [E(g_j(X_j))]$$

Demostración.- Supongamos que el vector $\vec{x} = (x_1, \dots, x_k)$ es continuo, entonces

$$E \left(\prod_{j=1}^k g_j(X_j) \right) = \int_{\mathbb{R}^k} \prod_{j=1}^k g_j(x_j) f_{\vec{x}}(x_1, \dots, x_k) dx_1 \dots dx_k = \int_{\mathbb{R}^k} \prod_{j=1}^k g_j(x_j) f_j(x_j) dx_j = \prod_{j=1}^k E(g_j(X_j))$$

Análogo razonamiento se aplica para el caso discreto.

Observación.- El inverso del lema no es cierto como podemos manifestar más tarde mediante un adecuado contraejemplo. (7)

COROLARIO.- Si X_1, X_2 son independientes, entonces son no correlados, siempre que existan los segundos momentos.

Demostración.- Recordemos que la correlación de dos variables aleatorias implica que su coeficiente de correlación es nulo. A su vez

$$\rho = \frac{cov(X_1, X_2)}{[\text{var}(X_1) \text{var}(X_2)]^{1/2}}$$

pero

$$cov(X_1, X_2) = E(X_1 X_2) - E(X_1) \cdot E(X_2) = E(X_1) \cdot E(X_2) - E(X_1) \cdot E(X_2) = 0$$

y por tanto $\rho = 0$.

Hay que señalar que la implicación de signo contrario, correlación $\rightarrow$ independencia no es cierta en general salvo para el caso de distribuciones normales multivariantes que más tarde veremos.

COROLARIO 2.- Si el vector $\vec{X} = (X_1, \dots, X_k)$ está constituido por variables aleatorias independientes, entonces

$$Y = \sum_{j=1}^k a_j X_j$$

tiene como varianzas

$$\text{var}(Y) = \sum_{j=1}^k a_j^2 \sigma_j^2, \text{ donde } \sigma_j^2 = \text{var}(X_j).$$

Demostración.- Recordemos que

$$\text{var}(X) = \sum_{j=1}^k a_j^2 \sigma_j^2 + 2 \sum_{j < i} a_j a_i \text{cov}(X_i, X_j)$$

y siendo independientes $cov(X_i, X_j) = 0, \forall i, j$ y de aquí el resultado.

Estamos ahora en condiciones de empezar la lectura del teorema de caracterización para funciones características.

TEOREMA (de factorización para funciones características).- Las variables aleatorias $X_j, j=1, \dots, k$ son independientes, si y sólo si

$$\varphi_{\vec{X}}(t_1, \dots, t_k) = \prod_{j=1}^k \varphi_{X_j}(t_j).$$

donde $\vec{X} = (X_1, \dots, X_k)$ y φ representa la función característica.

Demostración.- Si las X_j son independientes entonces $g_j(X_j) = e^{it_j X_j}$ también lo son, $j=1, \dots, k$. Entonces

$$\varphi_{\vec{X}}(t_1, \dots, t_k) = E[e^{i \sum_{j=1}^k t_j X_j}] = E\left[\prod_{j=1}^k e^{it_j X_j}\right]$$

Aplicando el lema 3, tendremos (8)

$$\varphi_{\vec{X}}(t_1, \dots, t_k) = \prod_{j=1}^k E[e^{it_j X_j}] = \prod_{j=1}^k \varphi_{X_j}(t_j).$$

Supongamos ahora que se verifica la anterior factorización. Sea $F_{\vec{X}}(x_1, \dots, x_k)$ la función de distribución del vector $\vec{X} = (X_1, \dots, X_k)$. Definamos

$$F(x_1, \dots, x_k) = \prod_{j=1}^k F_j(x_j)$$

donde $F_j(x_j)$ es la función de distribución de X_j . La función característica independiente a la distribución de probabilidad que $f(\vec{x})$ representa viene dada por $\prod_{j=1}^k \varphi_{X_j}(t_j)$, por lo que de acuerdo con la factorización citada dicha función será igual a la función característica $\varphi_{\vec{X}}(t_1, \dots, t_k)$ del vector $\vec{X}$, aplicando el teorema de unicidad $F_{\vec{X}}(x_1, \dots, x_k) = F(x_1, \dots, x_k)$ y por tanto son independientes las variables aleatorias $X_j, j=1, \dots, k$.

La independencia de las componentes de un vector aleatorio tiene gran incidencia al momento de obtener las distribuciones condicionadas. En efecto, sea $\vec{X} = (X_1, \dots, X_k)$ un vector cuyas componentes son independientes. Sean $\vec{X}_1 = (X_1, \dots, X_m)$ y $\vec{X}_2 = (X_{m+1}, \dots, X_k)$ dos subvectores que tienen también sus componentes independientes. Entonces

$$f_{\vec{X}_1/\vec{X}_2}(x_1) = \frac{f_{\vec{X}}(\vec{x})}{f_{\vec{X}_2}(x_2)}, \text{ con } \vec{x} = (x_1, x_2)$$

pero aplicando el teorema de factorización tenemos

$$f_{\vec{X}_1/\vec{X}_2}(x_1) = \frac{\prod_{j=1}^m f_j(x_j)}{\prod_{j=m+1}^k f_j(x_j)} = \prod_{j=1}^m f_j(x_j) = f_{\vec{X}_1}(x_1).$$

La independencia impone por lo tanto que el conocimiento previo de lo ocurrido con $\vec{X}_2$ no afecta para nada a lo que ocurrirá a $\vec{X}_1$.

Distribución e independencia en el caso normal.- Hemos visto que la independencia de dos variables aleatorias, impone su correlación. Ya hemos señalado que el recíproco no es cierto como podemos demostrar más tarde mediante un contraejemplo, salvo en un caso concreto del que nos ocuparemos en el teorema siguiente:

TEOREMA.- Sea $\vec{X} = (X_1, X_2)$ un vector normal bivariante. Entonces X_1, X_2 son independientes si y sólo si son no correlados.

Demostración.- Ya sabemos que

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}(x_1^2 - 2\rho x_1 x_2 + x_2^2)}$$

donde

$$q = \frac{1}{1-\rho^2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \frac{x_1 - \mu_1}{\sigma_1} \cdot \frac{x_2 - \mu_2}{\sigma_2} + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right]$$

ya sabemos que las marginales correspondientes vienen dadas por

$$f_1(x_1) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp \left[-\frac{(x_1 - \mu_1)^2}{2\sigma_1^2} \right], \quad f_2(x_2) = \frac{1}{\sqrt{2\pi}\sigma_2} \exp \left[-\frac{(x_2 - \mu_2)^2}{2\sigma_2^2} \right].$$

Observemos que si $\rho = 0$, entonces

$$f(x_1, x_2) = f_1(x_1) \cdot f_2(x_2)$$

con lo cual las variables X_1, X_2 son independientes.

INDEPENDENCIA DE VECTORES ALEATORIOS

El concepto de independencia se extiende de inmediato a familias de vectores aleatorios.

Definición. Los vectores $\vec{X}_j, j=1, \dots, k$ son independientes si lo son los σ -álgebras que miden.

Puede también enunciarse en términos de factorización para los vectores y puede también afirmarse que cualquier función medible de vectores aleatorios da lugar a nuevos vectores aleatorios.

Obsérvese, no obstante, que la independencia entre vectores aleatorios no afirma nada de los componentes de dichos vectores, de manera que puede ser perfectamente cierto que en cada vector no haya independencia entre sus componentes. Véase el siguiente ejemplo.

Ejemplo. Sea (X, Y) un vector aleatorio con función de densidad conjunta

$$f(x, y) = \frac{1}{4} [1 + xy(x^2 - y^2)], \quad |x| \leq 1, |y| \leq 1$$

y sea (U, V) un vector aleatorio con densidad conjunta

$$g(u, v) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} (u^2 - 2\rho uv + v^2) \right\}, \quad u \in \mathbb{R}, v \in \mathbb{R}, |\rho| < 1.$$

La densidad conjunta de (X, Y, U, V) viene dada por

$$h(x, y, u, v) = \frac{1}{8\pi\sqrt{1-\rho^2}} [1 + xy(x^2 - y^2)] \exp \left\{ -\frac{1}{2(1-\rho^2)} (u^2 - 2\rho uv + v^2) \right\}$$

y por tanto (X, Y) y (U, V) son independientes. Sin embargo X e Y , así como U, V , no son independientes.

9 ALGUNAS APLICACIONES DE LAS FUNCIONES CARACTERÍSTICAS

40

Volvamos en este apartado la utilidad de las funciones características para obtener la distribución de probabilidad de ciertas variables aleatorias definidas como suma de variables aleatorias independientes.

TEOREMA (Binomial). Sean X_j un conjunto de v.a. $B(n_j, p)$, $j=1, \dots, k$ e independientes. Entonces

$$Z = \sum_{j=1}^k X_j \quad \text{es una } B(n, p) \quad \text{con } n = \sum_{j=1}^k n_j.$$

Demonstración. Sabemos que

$$\varphi_{X_j}(t) = (pe^{it} + q)^{n_j}$$

entonces

$$\begin{aligned} \varphi_Z(t) &= E[e^{itZ}] = E[e^{it \sum_{j=1}^k X_j}] = E\left[\prod_{j=1}^k e^{itX_j}\right] = \prod_{j=1}^k E[e^{itX_j}] = \\ &= \prod_{j=1}^k \varphi_{X_j}(t) = \prod_{j=1}^k (pe^{it} + q)^{n_j} = (pe^{it} + q)^{\sum_{j=1}^k n_j}. \end{aligned}$$

La utilidad de esta propiedad aditiva de los binomiales con igual p los caracteriza, por cuanto puede enunciarse el recíproco del teorema que acabamos de demostrar, lo que supone que esto sólo ocurre para los binomiales de las características.

TEOREMA (Poisson). Sean X_j , $P(\lambda_j)$, $j=1, \dots, k$ e independientes. Entonces

$$Z = \sum_{j=1}^k X_j \quad \text{es } P(\lambda), \quad \text{con } \lambda = \sum_{j=1}^k \lambda_j.$$

Demonstración.

$$\begin{aligned} \varphi_Z(t) &= \prod_{j=1}^k \varphi_{X_j}(t) = \prod_{j=1}^k \exp(\lambda_j e^{it} - \lambda_j) = \exp(e^{it} \sum_{j=1}^k \lambda_j - \sum_{j=1}^k \lambda_j) = \\ &= \exp(e^{it} \lambda - \lambda), \quad \text{con } \lambda = \sum_{j=1}^k \lambda_j. \end{aligned}$$

Al igual que antes, también esta propiedad caracteriza a las distribuciones de Poisson por cuanto también, en esta ocasión, se cumple el recíproco. Hagámos una última propiedad que se deduce del teorema que acabamos de demostrar.

Corolario. Sean X e Y independientes con distribuciones $P(\lambda_1)$ y $P(\lambda_2)$ respectivamente. Entonces la distribución condicional de X , dada $Z = X + Y$ es una binomial.

Demonstración. La distribución de $Z = X + Y$, de acuerdo con lo anterior, es $P(\lambda_1 + \lambda_2)$. Entonces, para enteros m y n , $m \leq n$, tenemos

$$P(X=m, Y=n) = \frac{P(X=m, Y=n-m)}{P(X+Y=n)} = \frac{P(X=m) \cdot P(Y=n-m)}{P(X+Y=n)} =$$

$$= \frac{e^{-\lambda_1} \frac{\lambda_1^m}{m!} \cdot e^{-\lambda_2} \frac{\lambda_2^{n-m}}{(n-m)!}}{e^{-(\lambda_1+\lambda_2)} \frac{(\lambda_1+\lambda_2)^n}{n!}} =$$

$$= \frac{n!}{m!(n-m)!} \cdot \left(\frac{\lambda_1}{\lambda_1+\lambda_2}\right)^m \cdot \left(\frac{\lambda_2}{\lambda_1+\lambda_2}\right)^{n-m} = \binom{n}{m} p^m \cdot q^{n-m}$$

donde $p = \lambda_1/(\lambda_1+\lambda_2)$ y $q = 1-p = \lambda_2/(\lambda_1+\lambda_2)$, y se trata de una Binomial con parámetros n y $p = \lambda_1/(\lambda_1+\lambda_2)$.

TEOREMA (Normal).- Sean $X_j \sim N(\mu_j, \sigma_j^2)$, $j=1, \dots, k$ e independientes. Entonces

$$Z = \sum_{j=1}^k a_j X_j \sim N(\mu, \sigma^2), \text{ con } \mu = \sum_{j=1}^k a_j \mu_j \text{ y } \sigma^2 = \sum_{j=1}^k a_j^2 \sigma_j^2.$$

Demostración.-

$$\varphi_Z(t) = \prod_{j=1}^k E(e^{it a_j X_j}) = \prod_{j=1}^k \varphi_{X_j}(a_j t) = \prod_{j=1}^k \exp\left\{it a_j \mu_j - \frac{\sigma_j^2 a_j^2 t^2}{2}\right\} =$$

$$= \exp\left\{it \sum_{j=1}^k a_j \mu_j - \frac{t^2}{2} \sum_{j=1}^k a_j^2 \sigma_j^2\right\} = \exp\left\{it \mu - \frac{t^2 \sigma^2}{2}\right\}$$

con $\mu = \sum_{j=1}^k a_j \mu_j$ y $\sigma^2 = \sum_{j=1}^k a_j^2 \sigma_j^2$.

Una aplicación interesante de este teorema se produce en la siguiente situación:

Sean X_j , $j=1, \dots, k$ variables aleatorias independientes todas ellas con igual media, μ e igual varianza σ^2 . Definamos una nueva variable

$$\bar{X} = \sum_{j=1}^k X_j / k$$

por la propiedad de la media y la varianza y dada la independencia de las X_k , tenemos que

$$E(\bar{X}) = \mu \text{ y } \text{var}(\bar{X}) = \sigma^2/k.$$

Si todas las X_j son, además, normales, entonces

COROLARIO.- Sean $X_j \sim N(\mu, \sigma^2)$, $j=1, \dots, k$ e independientes. Entonces $\bar{X} = \sum_{j=1}^k X_j / k \sim N(\mu, \sigma^2/k)$

Demostración.- Basta aplicar el teorema con $a_j = 1/k$, $\mu_j = \mu$ y $\sigma_j^2 = \sigma^2$, $j=1, \dots, k$. Obsérvese que la variable $Z = \sqrt{k}(\bar{X} - \mu)/\sigma$ es $N(0,1)$.

(11) TEOREMA (χ^2).- Sean $X_j \sim \chi_{r_j}^2$, $j=1, \dots, k$ e independientes. Entonces

$$Z = \sum_{j=1}^k X_j \sim \chi_r^2 \text{ con } r = \sum_{j=1}^k r_j.$$

Se demuestra como los anteriores. Una aplicación interesante de este teorema es la siguiente:

Sean $X_j \sim N(\mu_j, \sigma_j^2)$, $j=1, \dots, k$ e independientes. Hemos visto en otro punto que las variables

$$Z_j = \frac{X_j - \mu_j}{\sigma_j} \text{ son } N(0,1) \text{ y, además, independientes, } j=1, \dots, k.$$

También son independientes la variable Z_j^2 y, además, como ya sabemos, son χ_1^2 , entonces aplicando el teorema

$$\sum_{j=1}^k Z_j^2 = \sum_{j=1}^k \left(\frac{X_j - \mu_j}{\sigma_j}\right)^2 \sim \chi_k^2.$$

TEOREMA (Cauchy).- Sean X_j v.a. Cauchy con $\mu=0$, $\sigma=1$, $j=1, \dots, k$ e independientes. Entonces

$$Z = \sum_{j=1}^k X_j$$

es una variable $k \cdot 1$, donde 1 es Cauchy con $\mu=0$, $\sigma=1$ y por tanto

$$\bar{X} = Z/k \text{ es Cauchy con } \mu=0, \sigma=1.$$

Demostración.-

$$\varphi_Z(t) = \prod_{j=1}^k \varphi_{X_j}(t) = \prod_{j=1}^k e^{-|t|} = e^{-k|t|}$$

que es la función característica de una variable $Zek \cdot 1$, con 1 Cauchy $\mu=0$, $\sigma=1$. La segunda afirmación es inmediata a partir de este resultado.

(12)

⇒ Un ejemplo para demostrar que la independencia no supone independencia.

Sean X_1, X_2 variables aleatorias que toman los valores $-1, 0, 1$ con los siguientes probabilidades

$X_1 \backslash X_2$	-1	0	1	
-1	α	β	α	$2\alpha + \beta$
0	β	0	β	2β
1	α	β	α	$2\alpha + \beta$
	$2\alpha + \beta$	2β	$2\alpha + \beta$	$4\alpha + 4\beta$

$\alpha, \beta > 0, \quad \alpha + \beta = \frac{1}{4}$

Entonces

$$\text{Cov}(X_1, X_2) = E(X_1 X_2) - E(X_1) \cdot E(X_2)$$

$$E(X_1 X_2) = (-1)(-1)\alpha + (-1)(1)\alpha + 1(-1)\alpha + 1(1)\alpha = \alpha - \alpha - \alpha + \alpha = 0$$

$$E(X_1) = -(2\alpha + \beta) + 2\alpha + \beta = 0$$

$$E(X_2) = -(2\alpha + \beta) + 2\alpha + \beta = 0$$

En consecuencia

$$\rho = \frac{\text{Cov}(X_1, X_2)}{\sigma(X_1) \cdot \sigma(X_2)} = 0$$

pero es evidente que la función de densidad conjunta no verifica la factorización

$$f(x_1, x_2) \neq f_1(x_1) \cdot f_2(x_2) \quad \text{donde } f_i \text{ es la marginal de } X_i.$$