

PROBABILIDAD

INTRODUCCIÓN INTUITIVA

La idea intuitiva es la siguiente: realizamos una experiencia N veces, de las cuales N_A ocurre el

suceso A . Entonces, $\lim_{N \rightarrow \infty} \frac{N_A}{N} = P(A)$

Se suele usar otra definición (equivalente) que permite hacer predicciones: se dividen todos los sucesos posibles en un número de sucesos equiprobables y:

$$P(A) = \frac{\text{n.º de sucesos favorables}}{\text{n.º de sucesos posibles}}$$

De estas definiciones deducimos:

$P \in \mathbb{R}$. Enón, $P \in [0, 1]$

$P = 1 \Leftrightarrow$ Certeza

$P = 0 \Leftrightarrow$ Imposibilidad

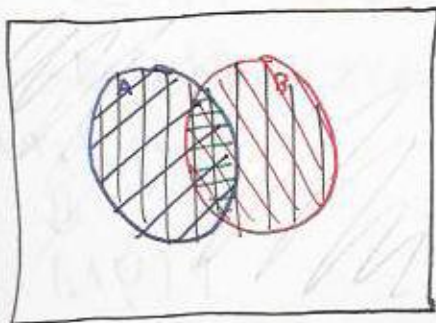
Si llamamos \bar{A} al suceso "no ocurre A ", $P(\bar{A}) = 1 - P(A)$ (para $N_{\bar{A}} + N_A = N$)

Esto último nos da la idea de definir nuevos sucesos:

ocurren A y $B \equiv A \cap B$

ocurre A o $B \equiv A \cup B$
↳ NO excluyente

Y haciendo una analogía entre el número de veces que ocurre algo y un área, esto se visualiza muy bien con diagramas de Venn:



N_A

N_B

$N_{A \cap B}$

$N_{A \cup B}$

N

→ Se deduce inmediata propiedad

↳ $N_{A \cup B} = N_A + N_B - N_{A \cap B}$

FORMULACIÓN RIGUROSA

- Sea β un conjunto al que pertenecen, al menos, U y \emptyset . Sobre β están definidas las operaciones \cap y \cup . Esto es un álgebra de Boole si se cumple:

IDENTIDAD: $A \cup \emptyset = A$
 $A \cap U = A$

CONMUTATIVA: $A \cap B = B \cap A$
 $A \cup B = B \cup A$

ASOCIATIVA: $A \cup (B \cap C) = (A \cup B) \cap C$
 $A \cap (B \cup C) = (A \cap B) \cup C$

DISTRIBUTIVA: $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$
 $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$

COMPLETITUD: $\exists \bar{A} \neq A$
 $A \cup \bar{A} = U$
 $A \cap \bar{A} = \emptyset$

Es el álgebra de la teoría de conjuntos (con $\beta = U$)

- Definimos la probabilidad como la siguiente aplicación de un álgebra de Boole a \mathbb{R} :

$$P: U \longrightarrow \mathbb{R}$$

$$A \longrightarrow P(A)$$

que cumple:

$$\cdot P(A) \geq 0$$

$$\cdot P(U) = 1$$

$$\cdot \forall i \neq j \quad A_i \cap A_j = \emptyset$$

\Downarrow

$$P\left(\bigcup_i A_i\right) = \sum_i P(A_i)$$

De los axiomas se deducen una serie de propiedades:

$$P(\emptyset) = 0$$

$$P(A) \in [0, 1]$$

$$P(\bar{A}) = 1 - P(A) \rightarrow \text{A veces es más fácil calcular } P(\bar{A})$$

$$\overline{A \cup B} = \bar{A} \cap \bar{B}$$


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

$$P\left(\bigcup_i A_i\right) = \sum_i P(A_i) - \sum_{\substack{i,j \\ i \neq j}} P(A_i \cap A_j) + \sum_{\substack{i,j,k \\ i \neq j \\ i \neq k \\ j \neq k}} P(A_i \cap A_j \cap A_k) - \dots$$

Se evalúan de menor a mayor al intentar todos los $\{A_i\}$ entre sí

APROXIMACIÓN PRÁCTICA

En la práctica, lo más útil es representar los sucesos en un diagrama de Venn:



- A_j (son excluyentes: omece o lie A o lie C o lie negro)
- D y \bar{D} son excluyentes y cubren $D \cup \bar{D} = U$
- ...

la probabilidad de un suceso es su área (todo área de $U = 1$)

Utilizo, si $\{C_i\}$ son excluyentes, $A = (A \cap C_1) \cup (A \cap C_2) \dots$

- Así, los datos de un problema nos dan ciertas áreas, nos divide todo U en diferentes regiones...
- y el problema de hallar probabilidades se reduce al de hallar áreas (suavado, restado...)
- Todos los sucesos, evidentemente, se podrán luego probar rigurosamente mediante las propiedades del álgebra de Boole y los axiomas de la probabilidad.

PROBABILIDAD CONDICIONADA (Puede ayudar a la hora de calcular $P(A \cap B)$)

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

: es, sabiendo que ha ocurrido B, la probabilidad de que además ocurra A.

modeliza el hecho de que un suceso influye a la probabilidad de que ocurra otro

Deducción:
• B ha ocurrido n veces
• $(A \cap B)$ ha ocurrido n' veces

\Rightarrow Por cada $\frac{n}{n'}$ veces que ocurre B, una ocurrencia A



Sabiendo que ha ocurrido B, la probabilidad de que haya ocurrido A es $\frac{1^{n'} \text{ veces favorables}}{n/n' \text{ total de sucesos}} = \frac{n'}{n}$

Teorema de Bayes:

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

(Se halla despejando $P(A \cap B)$ de $P(A|B)$ y $P(B|A)$ e igualando)

Esto nos permite definir:

A y B se dicen estadísticamente independientes $\Leftrightarrow P(A|B) = P(A)$

\rightarrow El hecho de que ocurra B no influye a la probabilidad de que ocurra A

Los sucesos estadísticamente independientes cumplen: (e. sustituir $P(A|B)$ por su definición)

$$A \text{ y } B \text{ estadísticamente independientes} \Leftrightarrow P(A \cap B) = P(A) \cdot P(B)$$

VARIABLES ALEATORIAS

Hasta ahora hemos trabajado con conjuntos, que se visualiza muy bien pero no nos permiten obtener resultados cuantitativos como medias, desviaciones...

Por esa razón, definiremos una variable aleatoria como una aplicación:

$$\begin{aligned} \xi: U &\longrightarrow \mathbb{R} \\ A &\longrightarrow \xi(A) = X \end{aligned}$$

Acorda siempre los sucesos en números

Convenios:

Por lo general, ξ sólo se define para sucesos elementales (sucesos cuya intersección es vacía y cuya unión forma U)

Se suele emplear el término variable aleatoria para el conjunto imagen.

Así, decir que x es una variable aleatoria equivale a decir que

$$\exists A \in U \text{ tal que } \xi(A) = x$$

\downarrow
elemental

Vamos ya a trabajar con variables aleatorias

VARIABLE DISCRETA :: es aquella a la que el conjunto imagen es contable (puede ser infinito)

Definimos la probabilidad de la variable discreta de manera obvia:

$$p(x) = \begin{cases} P(A) & \text{si } \exists A \text{ tal que } x = \xi(A) \\ 0 & \text{caso contrario} \end{cases}$$

notar que $\sum_i p(x_i) = 1$ (para $\forall A_i = U$; y $A_i \cap A_j = \emptyset \forall i \neq j$)

se define la función de probabilidad acumulada:

$$P(x) = \sum_{x \leq x_e} p(x) \quad \rightarrow \text{la probabilidad de que ocurra algo hasta } x_e$$
$$P(x_a \leq x \leq x_e) = \sum_{x_a \leq x \leq x_e} p(x)$$

VARIABLE CONTINUA: Cuando el conjunto imagen es un intervalo continuo

• Ahora es más difícil asignar probabilidades: el paso a \mathbb{R} requiere tomar límites, hacer los sucesos pequeños, y en el proceso la probabilidad de un suceso va a tender a 0

• Por tanto, sólo podemos definir probabilidades acumuladas: tomamos un conjunto continuo de sucesos, y a la vez que hacemos los sucesos pequeños, sumamos \Rightarrow INTEGRAMOS

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

\rightarrow la probabilidad de que ocurra algo antes de x

$$f(t) = \lim_{\Delta t \rightarrow 0} \frac{P(\{t, t+\Delta t\})}{\Delta t}$$

\Downarrow
Halla la probabilidad de que ocurra el suceso entre t y $t+\Delta t$ (a una nivel de detalle \Rightarrow un suceso) y divide esto Δt

Si tienes distribución de probabilidades

Es decir, $f(t) dt$ nos dice la probabilidad de que ocurra algo entre t y $t+dt$ ($f'(x) = f(x)$)

Concretar: $P(x_a \leq X \leq x_b) = \int_{x_a}^{x_b} f(x) dx$
 $\int_{-\infty}^{+\infty} f(x) dx = 1$

LAS VARIABLES DISCRETAS SE HACEN CONTINUAS CON DELTAS DE DIRAC:

$$f(x) = \sum_i f(x_i) \delta(x-x_i)$$

• Por último, es lógico extender la operación $A \cap B$:

Sean x y y dos variables aleatorias de probabilidad f_1, f_2 , respectivamente.

La probabilidad de que ocurran ambas se denota por $f(x, y)$

Si x y y son independientes, $f(x, y) = f_1(x) f_2(y)$

PROPIEDADES DE DISTRIBUCIONES

• VALOR MEDIO $\mu = \langle x \rangle = \int_{-\infty}^{+\infty} x p(x) dx = \sum_i x_i p(x_i)$

• Supongamos que te obtiene la siguiente lista de números:

- 1
- 1
- 2
- 3
- 5
- 5
- 4

• Hay N números
• Cada uno aparece N_i veces

El promedio se halla de nueva cuenta: $\frac{1+1+2+3+4+5+5}{N} =$

$$= \frac{1 \cdot N_1 + 2 \cdot N_2 + 3 \cdot N_3 + 4 \cdot N_4 + 5 \cdot N_5}{N}$$

$$= 1 \cdot \frac{N_1}{N} + 2 \cdot \frac{N_2}{N} + 3 \cdot \frac{N_3}{N} + 4 \cdot \frac{N_4}{N} + 5 \cdot \frac{N_5}{N} =$$

$$= \sum_i x_i p(x_i), \text{ donde se suma a todo el conjunto imagen}$$

En el caso continuo, $p(x_i)$ se sustituye por $p(x_i) \Delta x_i$, y al tomar $\Delta x_i \rightarrow 0$ queda una integral.
La probabilidad de que x esté entre x_i y $x_i + \Delta x$

• VALOR DE EXPECTACIÓN $\langle f(x) \rangle = \int_{-\infty}^{+\infty} f(x) p(x) dx = \sum_i f(x_i) p(x_i)$

• Sea la lista de números de antes. A cada número le asociamos otro (p.ej. si la lista de números es parcial, le asociamos la parte de la lista final que le corresponde)

Lo que se solicita

- 1 → $f(1)$
- 1 → $f(1)$
- 2 → $f(2)$
- 3 → $f(3)$
- 5 → $f(5)$
- 5 → $f(5)$
- 4 → $f(4)$

El promedio es fácil: $\frac{f(1) \cdot N_1 + f(2) \cdot N_2 + f(3) \cdot N_3 + f(4) \cdot N_4 + f(5) \cdot N_5}{N} =$

$$= \sum_i f(x_i) p(x_i), \text{ como antes}$$

MEDIANA

$$x_{50} \text{ es el valor para el que } P(x_{50}) = \frac{1}{2} = \int_{-\infty}^{x_{50}} f(t) dt$$

Es el valor que la probabilidad de que ocurra algo hasta él es $1/2$

MODA

Los valores de x para los que la distribución tiene un máximo

Es el valor más probable

VARIANZA

$$V = E[(x - \mu)^2]$$

Es lo que, en promedio, se va a alejar x de la media. Se eleva al cuadrado para evitar que los diferentes signos se compensen

DESVIACIÓN ESTÁNDAR

$$\sigma = \sqrt{V}$$

Verdad lo que en promedio es la distancia de x a μ , elevada al cuadrado. Como nos interesa la distancia, se toma la raíz

QUÁRTILES Y N-PERCENTILES

$$\text{Cuartil superior } x_{75} : P(x_{75}) = \frac{3}{4}$$

$$\text{Cuartil inferior } x_{25} : P(x_{25}) = \frac{1}{4}$$

$$n\text{-percentil} : x_n : P(x_n) = \frac{n}{100}$$

Nos dan idea de la anchura de la distribución

MOMENTOS

Generalizan todo lo visto hasta ahora

$$\mu_k = E[x^k]$$

μ_1 es el promedio

$$v_k = E[(x - \mu)^k]$$

v_2 es la Varianza
 v_k skew (sesión)

momento estandarizado

$$\gamma_k = \frac{v_k}{\sigma^k}$$

$\gamma_3 \equiv \gamma_3^1$ nos dice si hay más peso a la izquierda ($\gamma_3 < 0$) o a la derecha ($\gamma_3 > 0$)

γ_4 cuanto mayor sea, más picuda es la distribución

Completar una serie de propiedades:

• Si a es una constante, $E[a] = a$ (ya que $\int_{-\infty}^{\infty} f(x) dx = 1$)

• $E[\alpha f + \beta g] = \alpha E[f] + \beta E[g] \Rightarrow$ Es lineal

$$V = \langle x^2 \rangle - \langle x \rangle^2$$

• La probabilidad de que $|x - \mu| \geq c$, $\forall c \in \mathbb{R}$:

$$P(|x - \mu| \geq c) \leq \frac{\sigma^2}{c^2}$$

En particular, $P(|x - \mu| \geq n\sigma) \leq \frac{1}{n^2}$: la probabilidad de que x se aleje de la

media $n\sigma$ (a valor absoluto, dividiendo) o más es siempre menor que $\frac{1}{n^2}$.

Por último, nos podemos preguntar por la distribución de probabilidad de $y = f(x)$
(p.ej., conocer la probabilidad de recibir cierto monto lineal, y eso nos permitiría saber la región
posible; aunque preferiríamos saber la probabilidad de recibir cierto monto)

$$P_y(y) = P_x(x|y) \cdot \left. \frac{dx}{dy} \right|_{x|y}$$

DISTRIBUCIONES COMUNES

BINOMIAL: Sea un experimento con dos posibles resultados, el favorable (de probabilidad p) y el desfavorable (de probabilidad $1-p$)

DISCRETA

Si repetimos el experimento un número n de veces, ¿cuál es la probabilidad de que salgan k resultados favorables?

$$p(k) = \binom{n}{k} p^k (1-p)^{n-k} \quad ; \text{Aquí} \quad \begin{cases} \mu = np \\ \sigma = \sqrt{np(1-p)} \end{cases}$$

la variable aleatoria origina a cada suceso (cada conjunto de n tiradas) el número de resultados favorables

Demstración:

Quiero la probabilidad de que salga cierto resultado con k favorables y $n-k$ desfavorables. Como son sucesos independientes, para cada resultado esto

Vale $p^k (1-p)^{n-k}$
Probabilidad de que salgan k favorables

↓
Cada repetición es i.i.d. a la anterior

Ahora, $p(k)$ es la probabilidad de que salgan algunos de esos resultados. Esto es una unión de sucesos disjuntos (no pueden darse a la vez), así que tengo que sumar la probabilidad para cada uno de los $\binom{n}{k}$ sucesos que se valen (el orden en el que sale no importa). Como son equiprobables, $p(k) = \binom{n}{k} p^k (1-p)^{n-k}$

DISTRIBUCIÓN DE POISSON

DISCRETA

para medidas

• Cogemos la binomial y tomamos: $\begin{cases} \mu \text{ cte.} = \lambda \\ n \rightarrow +\infty \end{cases} (\Rightarrow p \rightarrow 0)$

$$p(k) = \frac{1}{k!} \lambda^k e^{-\lambda} \quad ; \text{aquí} \quad \begin{cases} \mu = \lambda \\ \sigma = \sqrt{\lambda} \end{cases}$$

Ejemplo: un detector compuesto por muchos de cierto número es una binomial. Ahora, si hago los tiradas cada vez más pequeñas, $n \rightarrow +\infty$ pero el producto de fotones detectados se mantiene cte. Así, la probabilidad de detectar k fotones es la de la distribución de Poisson pero que se dice a que la probabilidad de que un tirado detecte n fotones $\rightarrow 0$

DISTRIBUCIÓN GAUSSIANA O NORMAL

Es una distribución continua, buena aproximación de la binomial si $n \rightarrow +\infty$ (de hecho, para n pequeños uno lo usa para el test)

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}}$$

$$\begin{aligned} \mu &= \bar{x} \\ \sigma &= \sigma \end{aligned}$$

Para λ alto ($\sim 10, 15$), aproxima muy bien a la de Poisson: $P_{\text{Poisson}}(k) = \int_{k-1/2}^{k+1/2} N(\mu=\lambda, \sigma=\sqrt{\lambda}) dx$

Su utilidad radica en:

TEOREMA CENTRAL DEL LÍMITE: sea X una variable aleatoria, de media μ

y desviación estándar σ . Nos preguntamos por la distribución de probabilidad

de $a = \frac{x_1 + x_2 + \dots + x_n}{n}$, $f(a) \Rightarrow$ ¿Cuál es la distribución de probabilidad

del valor medio de x ? \Leftrightarrow ¿Cuál es la probabilidad de que el valor medio experimental esté entre a y $a+da$?

Según $n \rightarrow +\infty$,

$$f(a) \rightarrow \frac{1}{\sigma_a \sqrt{2\pi}} e^{-\frac{(a-\mu)^2}{2\sigma_a^2}}$$

$$\sigma_a = \frac{\sigma}{\sqrt{n}}$$

$$\frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{(a-\mu)^2}{2\sigma^2}}$$

\Rightarrow la distribución del valor medio experimental es una Gaussiana centrada en μ y de anchura σ_a

Si $n \rightarrow +\infty$, la anchura $\rightarrow 0$

SUMA DE POISSON/GAUSS

$$\begin{aligned} f(k_1) = P(\lambda_1) &\Rightarrow f(k_1 + k_2) = P(\lambda_1 + \lambda_2) = \frac{1}{(k_1 + k_2)!} e^{-(\lambda_1 + \lambda_2)} \\ f(k_2) = P(\lambda_2) &\end{aligned}$$

\rightarrow i.e., es como si se suman los fotones y se detectan

$$\begin{aligned} f(x_1) = N(\mu_1, \sigma_1) &\Rightarrow f(x_1 + x_2) = N(\mu_1 + \mu_2, \sqrt{\sigma_1^2 + \sigma_2^2}) \\ f(x_2) = N(\mu_2, \sigma_2) &\end{aligned}$$

36.9 IMPORTANT CONTINUOUS DISTRIBUTIONS




Figure 26.14 On the left, the standard Gaussian distribution $\phi(x)$; the shaded area gives $\Pr(Z < 1) = \Phi(1)$. On the right, the cumulative probability function $\Phi(x)$ for a standard Gaussian distribution $\phi(x)$.

From (26.105) we can define the cumulative probability function for a Gaussian distribution as

$$F(x) = \Pr(X < x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x \exp\left[-\frac{1}{2}\left(\frac{u-\mu}{\sigma}\right)^2\right] du, \quad (26.107)$$

where w is a dummy integration variable. Unfortunately, this (indefinite) integral cannot be evaluated analytically. It is therefore standard practice to tabulate values of the cumulative probability function for the standard Gaussian distribution (see figure 26.14), i.e.

$$\Phi(z) = \Pr(Z < z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z \exp\left(-\frac{t^2}{2}\right) dt, \quad (26.108)$$

It is usual only to tabulate $\Phi(z)$ for $z > 0$, since it can be seen easily, from figure 26.14 and the symmetry of the Gaussian distribution, that $\Phi(-z) = 1 - \Phi(z)$; see table 26.3. Using such a table it is then straightforward to evaluate the probability that Z lies in a given range of z -values. For example, for a and b constant,

$$\left. \begin{aligned} \Pr(Z < a) &= \Phi(a), \\ \Pr(Z > a) &= 1 - \Phi(a), \\ \Pr(a < Z \leq b) &= \Phi(b) - \Phi(a) \end{aligned} \right\}$$

Remembering that $Z = (X - \mu)/\sigma$ and comparing (26.107) and (26.108), we see that

$$F(x) = \Phi\left(\frac{x-\mu}{\sigma}\right),$$

and so we may also calculate the probability that the original random variable

PROBABILITY

$\Phi(z)$	00	01	02	03	04	05	06	07	08	09
0.0	5000	5040	5080	5120	5160	5199	5239	5279	5319	5359
0.1	5398	5438	5478	5517	5557	5596	5636	5675	5714	5753
0.2	5793	5832	5871	5910	5948	5987	6026	6064	6103	6141
0.3	6179	6217	6255	6293	6331	6368	6406	6443	6480	6517
0.4	6554	6591	6628	6664	6700	6736	6772	6808	6844	6879
0.5	6915	6950	6985	7019	7054	7088	7123	7157	7190	7224
0.6	7257	7291	7324	7357	7389	7422	7454	7486	7517	7549
0.7	7580	7611	7642	7673	7704	7734	7764	7794	7823	7853
0.8	7881	7910	7939	7967	7995	8023	8051	8078	8106	8133
0.9	8159	8186	8212	8238	8264	8289	8315	8340	8365	8389
1.0	8413	8438	8461	8485	8508	8531	8554	8577	8599	8621
1.1	8643	8665	8686	8708	8729	8749	8770	8790	8810	8830
1.2	8849	8869	8888	8907	8925	8944	8962	8980	8997	9015
1.3	9032	9049	9066	9082	9099	9115	9131	9147	9162	9177
1.4	9192	9207	9222	9236	9251	9265	9279	9292	9306	9319
1.5	9332	9345	9357	9370	9382	9394	9406	9418	9429	9441
1.6	9452	9463	9474	9484	9495	9505	9515	9525	9535	9545
1.7	9554	9564	9573	9582	9591	9599	9608	9616	9625	9633
1.8	9641	9649	9656	9664	9671	9678	9686	9693	9699	9706
1.9	9713	9719	9726	9732	9738	9744	9750	9756	9761	9767
2.0	9772	9778	9783	9788	9793	9798	9803	9808	9812	9817
2.1	9821	9826	9830	9834	9838	9842	9846	9850	9854	9857
2.2	9861	9864	9868	9871	9875	9878	9881	9884	9887	9890
2.3	9893	9895	9898	9901	9904	9906	9908	9911	9913	9916
2.4	9918	9920	9922	9925	9927	9929	9931	9932	9934	9936
2.5	9938	9940	9941	9943	9945	9946	9948	9949	9951	9952
2.6	9953	9955	9956	9957	9959	9960	9961	9962	9963	9964
2.7	9965	9966	9967	9968	9969	9970	9971	9972	9973	9974
2.8	9974	9975	9976	9977	9977	9978	9979	9979	9980	9981
2.9	9981	9982	9982	9983	9984	9984	9985	9985	9986	9986
3.0	9987	9987	9987	9988	9988	9989	9989	9989	9990	9990
3.1	9990	9991	9991	9991	9992	9992	9992	9992	9993	9993
3.2	9993	9993	9994	9994	9994	9994	9994	9995	9995	9995
3.3	9995	9995	9995	9996	9996	9996	9996	9996	9996	9997
3.4	9997	9997	9997	9997	9997	9997	9997	9997	9997	9998

Table 26.3 The cumulative probability function $\Phi(z)$ for the standard Gaussian distribution, as given by (26.108). The units and the first decimal place of z are specified in the column under $\Phi(z)$ and the second decimal place is specified by the column headings. Thus, for example, $\Phi(1.23) = 0.8907$.

$$E_{10} \text{ tabula } \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt = \Phi(z)$$

$$\text{Si qumero } \Phi(z) = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^z e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx = \left| \frac{x-\mu}{\sigma} = t \right| \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$$

$$\Psi(z) = \Phi\left(\frac{z-\mu}{\sigma}\right)$$

FUNCIÓN CARACTERÍSTICA / GENERATRIZ DE UNA DISTRIBUCIÓN

Es su transformada de Fourier: $f(x) \rightarrow \underline{\Phi}(k) = \int_{-\infty}^{+\infty} dx e^{ikx} f(x)$

Al desarrollar en Taylor la exponencial, aparecen los momentos $\Rightarrow \frac{d^n \Phi}{dk^n} \Big|_{k=0} \propto \mu_n$

Es decir, una distribución queda caracterizada por sus momentos.

Esto vale para densidad T.C.L.

