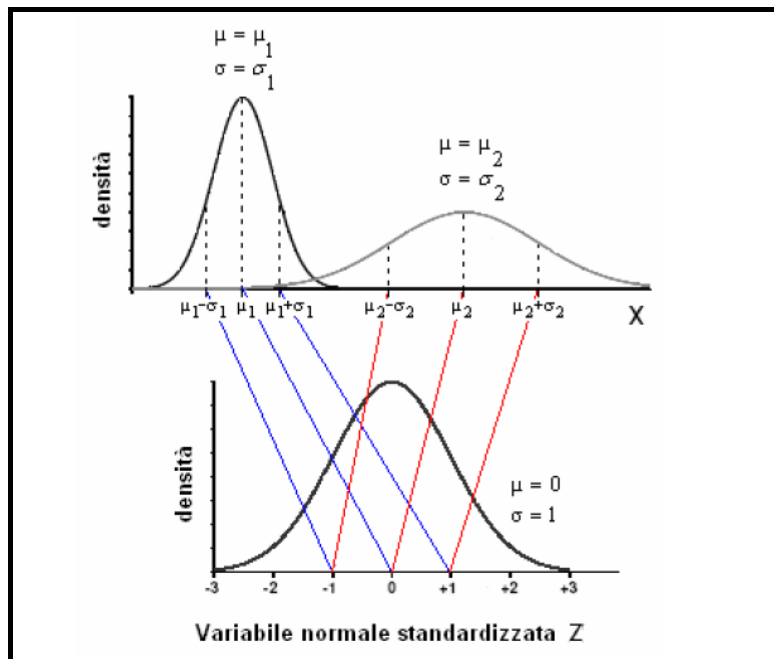


FACOLTA' DI INGEGNERIA

CORSO DI LAUREA IN INGEGNERIA CIVILE

CORSO DI IDROLOGIA

PROF. PASQUALE VERSACE



SCHEDA DIDATTICA N°7

LA DISTRIBUZIONE NORMALE

A.A. 2012-13

La distribuzione NORMALE

Uno dei più importanti esempi di distribuzione di probabilità continua è dato dalla *distribuzione Normale* (*curva normale o distribuzione Gaussiana*); è una delle più usate in statistica sia perché molti fenomeni si distribuiscono “normalmente”, sia perché altre funzioni di probabilità (ad es. la binomiale) possono essere approssimate da essa.

Per i matematici è di grande utilità il ragionare su distribuzioni basate su un numero di casi infinitamente “grandi”. Infatti, il *Teorema Limite Centrale* stabilisce che la distribuzione della somma o della media di un campione casuale di n valori estratti da una popolazione ha una distribuzione normale per un numero elevato n . La distribuzione normale è detta anche curva degli errori accidentali o di Gauss.

La *distribuzione Normale* è definita dall'equazione:

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

con *variabile casuale*

$$x \in]-\infty; +\infty [$$

e *parametri*

$$\mu = \text{media} \in]-\infty; +\infty [$$

$$\sigma^2 = \text{varianza} \in]0; +\infty [;$$

Per indicare una v.c. X distribuita in maniera Normale con parametri μ e σ^2 si usa in genere la notazione $X \sim N(\mu, \sigma^2)$.

Sulla $f_X(x)$ Normale si possono fare alcune considerazioni:

- 1) $f_X(x) \geq 0 \quad \forall x$;
- 2) $\int_{-\infty}^{+\infty} f_X(x) dx = 1$;
- 3) $f_X(x)$ è tanto più grande quanto più è piccolo l'esponente, ovvero quanto più x è vicino a μ , e raggiunge il suo massimo per $x = \mu$ (moda, media e mediana coincidono);
- 4) $f_X(x)$ possiede due flessi, cioè due punti in cui cambia concavità, in $\mu - \sigma$ e $\mu + \sigma$;
- 5) $f_X(x)$ è simmetrica intorno ad $x = \mu$, cioè per ogni coppia di ascisse $x_1 = \mu - c$ e $x_2 = \mu + c$ aventi la stessa distanza c dall'asse di simmetria, $f_X(x_1) = f_X(x_2)$;

Poiché π ed e sono costanti per conoscere l'esatta forma della distribuzione è necessario conoscere la media μ e lo scarto quadratico medio σ . Si avranno, pertanto, diverse curve normali quanti sono le possibili combinazioni di medie e scarti quadratici medi. Per esempio, due curve con medie uguali e scarto diverso differiranno per quanto riguarda la forma che sarà più o meno appuntita: se minore è lo scarto quadratico medio, la curva è più appuntita. Come illustrato delle figure 1 e 2 e nell'esempio successivo,

- μ determina la posizione della curva sull'asse delle ascisse. È il **parametro di posizione**, al variare del suo valore, la curva non cambia nella forma ma subisce una traslazione rispetto all'asse orizzontale;
- σ^2 determina la maggiore o minore concentrazione della curva intorno a μ . È il **parametro di scala**: al suo variare cambia la forma della curva di distribuzione. In particolare, per bassi valori di σ , l'area sotto la curva è concentrata intorno alla media, mentre per alti valori la curva è "schiacciata" rispetto all'asse orizzontale.




Figura 1 - Distribuzione di una variabile casuale Normale con varianza fissa e differenti medie





Figura 2- Distribuzione di una variabile casuale Normale con media fissa e differenti varianze

ESEMPIO: Altezza di uomini e donne

Nella figura che segue la moda della curva che descrive la distribuzione dell'altezza delle donne è più alta di quella degli uomini: significa che le donne sono più alte degli uomini?

NO!




Gli uomini sono in media più alti delle donne perché la loro curva è più a destra, cioè verso valori di X (altezza) maggiori. Poiché le altezze dei maschi hanno una variabilità maggiore, la curva dei maschi è più bassa e larga (entrambe le aree sottese valgono 1).

Se un fenomeno si distribuisce secondo una distribuzione Normale si ha che:

- circa il 68% di tutti i valori cade nell'intervallo di ± 1 deviazione standard dalla media

$$P[\mu - \sigma \leq x \leq \mu + \sigma] = 0.6826$$



analogamente:

- il 95% dei valori cade nell'intervallo di ± 1.96 deviazioni standard dalla media

$$P[\mu - 1.96\sigma \leq x \leq \mu + 1.96\sigma] = 0.95$$

- e per 3 sigma ...

$$P[\mu - 3\sigma \leq x \leq \mu + 3\sigma] = 0.9974.$$

Essendo infinite le curve normali al variare della media e dello scarto quadratico medio è sorta la necessità di costruire una curva a cui fare riferimento e di cui sono state calcolate le aree.

Un caso particolare della v.c. Normale, utile nelle applicazioni, è la v.c. *Normale Standardizzata*, convenzionalmente indicata con Z (oppure U), così definita:

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

e per la quale si ha $\mathbf{E}[Z] = \mathbf{0}$ e $\mathbf{Var}[Z] = \mathbf{1}$.


La distribuzione normale standardizzata, infatti, è una particolare normale di valor medio nullo e varianza unitaria. E' possibile dimostrare che:

$$f_z(z)dz = f_x(x)dx$$

e verificare quindi:

$$E[Z] = \int_{-\infty}^{+\infty} z \cdot f_z(z)dz = \int_{-\infty}^{+\infty} \frac{x - \mu}{\sigma} \cdot f_x(x)dx = \frac{1}{\sigma} \left[\int_{-\infty}^{+\infty} x \cdot f_x(x)dx - \mu \int_{-\infty}^{+\infty} f_x(x)dx \right] = \frac{1}{\sigma} [\mu - \mu \cdot 1] = 0$$

$$Var[Z] = \int_{-\infty}^{+\infty} z^2 \cdot f_z(z)dz = \int_{-\infty}^{+\infty} \left(\frac{x - \mu}{\sigma} \right)^2 f_x(x)dx = \frac{1}{\sigma^2} \int_{-\infty}^{+\infty} (x - \mu)^2 f_x(x)dx = \frac{1}{\sigma^2} \cdot \sigma^2 = 1$$



Data una v.c. $X \sim N(\mu, \sigma^2)$ è possibile passare ad una v.c. Normale Standardizzata $Z \sim N(0,1)$ (e viceversa) attraverso la relazione (2).

Per la variabile standardizzata la *p.d.f.* e la *c.d.f.* diventano rispettivamente:


$$f_z(z) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{1}{2}z^2\right]$$

$$F_z(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z \exp\left(-\frac{v^2}{2}\right) dv$$

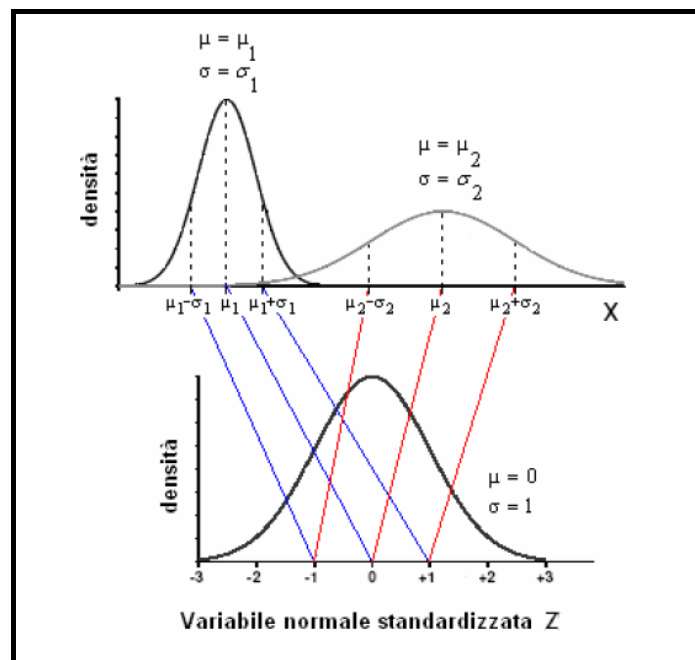
Per la variabile casuale Z , non essendo la distribuzione dipendente da alcun parametro, sono stati tabulati i valori della *p.d.f.* e della *c.d.f.* (vedi Tabella 1 allegata).

Inoltre è possibile dimostrare che:

$$F_Z(z) = F_X(x) \tag{3}$$



Graficamente:




Graficamente la trasformazione della variabile originaria in variabile standardizzata si ottiene passando dal sistema cartesiano ortogonale al sistema con asse Z con la curva al valore massimo nell'origine e flessi a -1, +1. Fatta la trasformazione, si possono usare, quindi, le apposite tavole per il calcolo delle porzioni di aree sottese.

In tabella 1 è riportata la tavola delle aree sotto la curva normale standardizzata comprese tra l'ascissa 0 e qualsiasi valore positivo fino a 3,99. Servendosi di questa tavola è possibile trovare la aree (e quindi probabilità) comprese tra due ascisse qualsiasi, ricordando la simmetria della curva intorno alla media che coincide con il valore $z=0$.

Come si procede per calcolare le probabilità nel caso di una v.c. Normale con l'ausilio della v.c. standardizzata?

- Si definiscono la v.c. X, i valori di μ e σ e l'evento di interesse
- Si calcola il valore standardizzato z
- Si disegna la curva normale individuando sul grafico l'area di interesse
- Si usano tavole, simmetria e probabilità dell'evento complementare (1- ...) per calcolare il valore della probabilità (area) che si desidera.

Se ho un valore di $z < 0$? Si osserva che: $F_Z(-z) = 1 - F_Z(z)$



AREA A = AREA B

AREA B = 1 - F_Z(z)

N.B.-Consultando la tavola è importante ricordare che i valori z sono sull'asse delle ascisse e non confonderli con le aree. I valori di z possono essere negativi, le aree non lo sono mai!

ESEMPI: Variabile standardizzata

1) Si calcoli, utilizzando la tabella 1, la probabilità $P[Z \leq 3]$ ovvero $F_Z(3)$.


Nella tabella 1 procedere verso il basso nella colonna segnata z fino a raggiungere il valore 3. Quindi procedere verso destra fino alla colonna segnata 0. Il valore 0.4987 che si individua è l'area sottesa a partire dall'ascissa 0; per ottenere l'area richiesta, tenendo conto della simmetria della curva, bisogna aggiungere a tale valore 0.5.

$F_Z(3) = 0.4987 + 0.5 = 0.9987$ rappresenta la probabilità che z sia minore od uguale a 3.

2) Si calcoli la probabilità $P[-1.96 \leq Z \leq 1.96]$.

E' necessario calcolare $[F_Z(1.96) - F_Z(-1.96)]$ ovvero l'area compresa tra $z = -1.96$ e $z = 1.96$.

Per trovare l'area compresa tra 0 e 1.96 procedere verso il basso nella colonna segnata z fino a raggiungere il valore 1.9. Quindi procedere a destra fino alla colonna segnata 6. Il valore 0.475 per simmetria rappresenta anche l'area compresa tra -1.96 e 0. Pertanto la probabilità richiesta risulta $P[-1.96 \leq Z \leq 1.96] = 0.475 + 0.475 = 0.95$.



3) Trovare la probabilità $P[Z \leq -0.6]$ ovvero $F_Z(-0.6)$.

L'area richiesta si trova a sinistra del valore $z = 0$; sulla tabella è, invece, possibile trovare il valore dell'area compresa tra 0 e 0.6. che risulta pari a 0.2258.

Considerando la simmetria della curva si ha

$$F_Z(-z) = 1 - F_Z(z)$$

da cui

$$F_Z(-0.6) = 1 - F_Z(0.6) = 1 - (0.5 + 0.2258) = 0.2742$$

4) Trovare la probabilità $P[Z \geq -1.28]$.

L'area richiesta = (area compresa tra $z = -1.28$ e $z = 0$) + (area a destra di $z = 0$). Sulla tabella troviamo il valore del primo termine individuando il valore per 1.28, mentre il secondo termine è pari a 0.5.

Quindi si ha:

$$P[Z \geq -1.28] = 0.3997 + 0.5 = 0.8997$$

5) Trovare la probabilità $P[Z \geq 2.05] = 1 - F_Z(2.05)$.

L'area richiesta è l'area a destra di $z = 2.05$. Sulla tabella troviamo il valore dell'area compresa tra 0 e 2.05; per ottenere $F_Z(2.05)$ aggiungiamo l'area a sinistra di $z=0$ cioè 0.5.

$$F_Z(2.05) = 0.4798 + 0.5 = 0.9798$$

Quindi si ha:

$$P[Z \geq 2.05] = 1 - F_Z(2.05) = 1 - 0.9798 = 0.0202.$$

Analogamente partendo dal valore della probabilità è possibile, attraverso la tabella, individuarne il corrispondente frattile.

6) Trovare il valore della variabile standardizzata Z cui corrisponde una probabilità di non superamento pari a 0.95.

E' necessario, quindi, calcolare il frattile $z_{0.95}$ a cui corrisponde $F_Z(z_{0.95})=0.95$.

Poiché nella tabella sono riportate le aree a destra di $z = 0$, bisogna individuare il valore $0.45 = 0.95 - 0.5$. Tale valore risulta compreso tra quelli riportati tra $z = 1.64$ e $z = 1.65$.

Effettuando un'interpolazione lineare tra tali valori si ha:

$$\frac{1.65 - 1.64}{0.4505 - 0.4495} = \frac{1.65 - z}{0.4505 - 0.45}$$
$$z = 1.65 - (0.4505 - 0.45) \cdot \frac{1.65 - 1.64}{0.4505 - 0.4495} = 1.645$$

ESEMPIO distribuzione Normale

1) Si assuma che la v.c. altezza delle donne di età maggiore ai 18 anni, in Calabria, è distribuita secondo la legge Normale.

La media e lo scarto quadratico medio dell'altezza delle donne sono rispettivamente 158 cm e 15 cm.

a) Si calcoli la probabilità che l'altezza di una donna sia compresa tra $x_1 = 140$ cm e $x_2 = 170$ cm.

Per rispondere al quesito è necessario utilizzare la tabella e pertanto considerare i valori standardizzati.

$$z_1 = \frac{x_1 - \mu}{\sigma} = \frac{140 - 158}{15} = -1.2$$

$$z_2 = \frac{x_2 - \mu}{\sigma} = \frac{170 - 158}{15} = 0.8$$

Dalla tabella si ha:

$$F_Z(-1.2) = 1 - F_Z(1.2) = 1 - (0.5 + 0.3849) = 1 - 0.8849 = 0.1151$$

$$F_Z(0.8) = 0.5 + 0.2881 = 0.7881$$

Per la relazione (3) risulta:

$$F_Z(-1.2) = F_X(140)$$

$$F_Z(0.8) = F_X(170)$$

La probabilità richiesta è quindi:

$$P[170 \leq X \leq 140] = F_X(170) - F_X(140) = F_Z(0.8) - F_Z(-1.2) = 0.7881 - 0.1151 = 0.673.$$

Su un campione di 1000 donne ad esempio il 67.3 %, ovvero 673, hanno un'altezza compresa tra 140 e 170 cm.

b) si calcoli la probabilità che l'altezza di una donna sia maggiore di 185 cm.

Considerando la variabile standardizzata

$$z = \frac{x - \mu}{\sigma} = \frac{185 - 158}{15} = 1.8$$

dalla tabella si ha :

$$P[Z \leq 1.8] = F_Z(1.8) = 0.5 + 0.4641 = 0.9641$$

Quindi:

$$P[Z \geq 1.8] = 1 - F_Z(1.8) = 0.0359$$

$$P[X \geq 185] = 1 - F_X(185) = 0.0359$$

c) l'altezza cui corrisponde una probabilità di non superamento del 30%.

$$F_X(x_{0.3}) = F_Z(z_{0.3}) = 0.3.$$

La variabile standardizzata $z_{0.3}$ in questo caso sarà negativa e, quindi, è necessario considerare la relazione

$$F_Z(-z) = 1 - F_Z(z)$$

Si ha:

$$F_Z(-z) = 1 - F_Z(z) = 1 - 0.3 = 0.7$$

Poiché nella tabella sono riportati i valori per $z > 0$ è necessario cercare l'area pari a $0.7 - 0.5 = 0.2$.

Tale valore si ha in corrispondenza di 0.525 (è stata effettuata un'interpolazione lineare) per cui $z_{0.3} = -0.525$.

Per tornare alla v.c. X (altezza in cm) si utilizza la relazione (2).

$$x_{0.3} = \sigma \cdot z_{0.3} + \mu = 15 \cdot (-0.525) + 158 = 150.125 \text{ cm}$$

