


# Metodi Quantitativi per Economia, Finanza e Management

## *Lezione n°3*

Analisi Univariata

# Quantitative Market Research

## Set-up Protocol



### facebook


#### 4 Factors

Our choice was consistent with the following criteria:

- The proportion between the maximum number of variables and the chosen factors is in the acceptable range (4/13 < 30%)
- The Eigenvalues are all bigger than 1
- The Cumulative Variance Explained is over 60%
- Communalities homogeneous values

As the Scree Plot confirms, only after 4 components the slope of the curve sensibly decreases.

NUMBER OF FACTORS (K/P)	OK
EINGENVALUE (> 1)	OK
% global explained variance (Between 60 and 75%)	62% - OK
Communalities - Low difference between highest and lowest (+30%)	79% - 50% = 29% - OK



### facebook

#### The 5 Clusters

- **Cool Hunters (28%)**: More than all, they are users absolutely interested on **Broadening**.
- **PR's (7%)**: Interested above all in **Public Relations** and express some attachment to **Spying**, but not related at all with **Keeping Up**.
- **Detached (20%)**: Apart from some light interest on **Broadening**, they do not express any involvement with the Facebook use (in particular with **Public Relations**).
- **Functional (18%)**: Above all, interested in **Keeping up** with their network of friends and use **Public Relations** inside this network. Besides, they do not care at all about **Spying** and **Broadening**.
- **Gossipers (27%)**: They are also interested in **Keeping up**, but above all in **Spying** their network. Furthermore, they are not interested in **Public Relations** and **Broadening**.

Each single Cluster was then crossed with socio-demographic and usage variables, through the contingency table tool, in order to better understand their main characteristics. The following slides sum-up the most relevant results of these crossings for each single cluster.


# Univariate descriptive statistics

In the univariate descriptive statistics we analyze one variable at a time.


N_ID	D_8_2
H1	0.1
H2	0
H3	0
H4	0.2
H5	0.05
H6	0.2
H7	0.1
H8	0.1
H9	0.2
H10	0.05
H11	0
H12	0
H13	0
H14	0.15
H15	0
H16	0.1
H17	0
H18	0.2
H19	0
H20	0.05
H21	0.2
H22	0.2

...

H234	0.2
H235	0.1
H236	0.1



- Frequency distribution
- Synthesis measures
  - *Measures of location*
  - *Measures of spread*
  - *Measures of shape*



- Data Audit
  - Input errors
  - Missing values
  - Outliers
- Basic insights

# Le distribuzioni di frequenza



- *Frequenza assoluta*: è un primo livello di sintesi dei dati- consiste nell'associare a ciascuna categoria, o modalità, il numero di volte in cui compare nei dati
- *Distribuzione di frequenza*: insieme delle modalità e delle loro frequenze
- *Frequenza relativa*: rapporto tra la frequenza assoluta ed il numero complessivo delle osservazioni effettuate.

$$p_i = n_i / N$$

I due tipi di frequenze vengono usati con dati qualitativi e quantitativi discreti.

# Le distribuzioni di frequenza

- *Rappresentazione grafica var.qualitative:*





*Diagr. a barre:* nell'asse delle ascisse ci sono le categorie, senza un ordine preciso; in quello delle ordinate le frequenze assolute/relative corrispondenti alle diverse modalità

*Diagr. a torta:* la circonferenza è divisa proporzionalmente alle frequenze

# Le distribuzioni di frequenza

- *Rappresentazione grafica var. quantitative discrete:*



*Diagr. delle frequenze:* nell'asse delle ascisse ci sono i valori assunti dalla var. discreta (quindi ha un significato quantitativo); l'altezza delle barre è proporzionale alle frequenze relative o assolute del valore stesso

*Istogramma:* nell'asse delle ascisse ci sono le classi degli intervalli considerati; l'asse delle ordinate rappresenta la densità di frequenza; l'area del rettangolo corrisponde alla frequenza della classe stessa.

# Misure di sintesi

## *Misure di tendenza centrale:*

- Media aritmetica
- Mediana
- Moda

## *Misure di tendenza non centrale:*

- Quantili
- Percentili


## *Misure di dispersione:*

- Campo di variazione
- Differenza interquantile
- Varianza
- Scarto quadratico medio
- Coefficiente di variazione

## *Misure di forma della distribuzione:*


- Skewness
- Kurtosis

# Misure di Tendenza Centrale




# Media Aritmetica

- La misura di tendenza centrale più comune
- Media = somma dei valori diviso il numero di valori
- Influenzata da valori estremi (outlier)



**Media = 3**

$$\frac{1+2+3+4+5}{5} = \frac{15}{5} = 3$$





**Media = 4**

$$\frac{1+2+3+4+10}{5} = \frac{20}{5} = 4$$

# Mediana



- In una lista ordinata, la mediana è il valore “centrale” (50% sopra, 50% sotto)



- Non influenzata da valori estremi


# Moda

- Valore che occorre più frequentemente
- Non influenzata da valori estremi
- Usata sia per dati numerici che categorici
- Può non esserci una moda
- Ci può essere più di una moda




# Misure di Tendenza Non Centrale

- I Quartili dividono la sequenza ordinata dei dati in 4 segmenti contenenti lo stesso numero di valori



- Il primo quartile,  $Q_1$ , è il valore per il quale 25% delle osservazioni sono minori e 75% sono maggiori di esso
- $Q_2$  coincide con la mediana (50% sono minori, 50% sono maggiori)
- Solo 25% delle osservazioni sono maggiori del terzo quartile

# Box Plot




## OUTLIERS:


$Q1 - 1,5 * \text{Differenza interquartile}$

$Q3 + 1,5 * \text{Differenza interquartile}$

# Misure di Variabilità



- Le misure di variabilità forniscono informazioni sulla **dispersione** o **variabilità** dei valori.




Stesso centro,  
diversa variabilità

# Campo di Variazione

- La più semplice misura di variabilità
- Differenza tra il massimo e il minimo dei valori osservati:

$$\text{Campo di variazione} = X_{\text{massimo}} - X_{\text{minimo}}$$


Esempio:




$$\text{Campo di Variazione} = 14 - 1 = 13$$

# Campo di Variazione

- Ignora il modo in cui i dati sono distribuiti



$$\text{Campo di Var.} = 12 - 7 = 5$$



$$\text{Campo di Var.} = 12 - 7 = 5$$

- Sensibile agli outlier

1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 2, 2, 2, 2, 2, 2, 2, 2, 2, 2, 3, 3, 3, 3, 4, 5

$$\text{Campo di Var.} = 5 - 1 = 4$$

1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 2, 2, 2, 2, 2, 2, 2, 2, 3, 3, 3, 3, 4, 120

$$\text{Campo di Var} = 120 - 1 = 119$$

# Differenza Interquartile

- Possiamo eliminare il problema degli outlier usando la differenza interquartile
- Elimina i valori osservati più alti e più bassi e calcola il campo di variazione del 50% centrale dei dati
- Differenza Interquartile = 3° quartile – 1° quartile

$$\text{IQR} = Q_3 - Q_1$$

# Varianza

- Media dei quadrati delle differenze fra ciascuna osservazione e la media

– Varianza della Popolazione:

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

dove

$\mu$  = media della popolazione

$N$  = dimensione della popolazione

$x_i$  =  $i^{\text{mo}}$  valore della variabile  $X$

# Scarto Quadratico Medio

- Misura di variabilità comunemente usata
- Mostra la variabilità rispetto alla media
- Ha la stessa unità di misura dei dati originali


– Scarto Quadratico Medio della Popolazione:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$$

# Scarto Quadratico Medio


Scarto quadratico medio piccolo

Scarto quadratico medio grande




# Scarto Quadratico Medio

Dati A




Media = 15.5  
S = 3.338

Dati B



Media = 15.5  
S = 0.926

Dati C



Media = 15.5  
S = 4.570

# Scarto Quadratico Medio

- Viene calcolato usando tutti i valori nel set di dati
- Valori lontani dalla media hanno più peso  
(poichè si usa il quadrato delle deviazioni dalla media)
- Le stesse considerazioni valgono anche per il calcolo della Varianza

# Coefficiente di Variazione

- Misura la variabilità relativa
- Sempre in percentuale (%)
- Mostra la variabilità relativa rispetto alla media
- Può essere usato per confrontare due o più set di dati misurati con unità di misura diversa

$$CV = \left( \frac{s}{|\bar{X}|} \right) \cdot 100\%$$

# Coefficiente di Variazione

- Azione A:
  - Prezzo medio scorso anno = \$50
  - Scarto Quadratico Medio = \$5

$$CV_A = \left( \frac{s}{|\bar{X}|} \right) \cdot 100\% = \frac{\$5}{\$50} \cdot 100\% = 10\%$$



- Azione B:
  - Prezzo medio scorso anno = \$100
  - Scarto Quadratico Medio = \$5

$$CV_B = \left( \frac{s}{|\bar{X}|} \right) \cdot 100\% = \frac{\$5}{\$100} \cdot 100\% = 5\%$$

Entrambe le azioni hanno lo stesso scarto quadratico medio, ma l'azione B è meno variabile rispetto al suo prezzo

# Forma della Distribuzione


- La forma della distribuzione si dice simmetrica se le osservazioni sono bilanciate, o distribuite in modo approssimativamente regolare attorno al centro.




# Forma della Distribuzione

- La forma della distribuzione è detta asimmetrica se le osservazioni non sono distribuite in modo simmetrico rispetto al centro.

Una distribuzione con **asimmetria positiva** (obliqua a destra) ha una coda che si estende a destra, nella direzione dei valori positivi.



Una distribuzione con **asimmetria negativa** (obliqua a sinistra) ha una coda che si estende a sinistra, nella direzione dei valori negativi.




# Misure di Forma della Distribuzione

- Descrive come i dati sono distribuiti
- Misure della forma
  - Simmetrica o asimmetrica


**Obliqua a sinistra**

**Media < Mediana**




**Simmetrica**

**Media = Mediana**



**Obliqua a destra**

**Mediana < Media**



# Misure di Forma della Distribuzione

**Skewness:** indice che informa circa il grado di simmetria o asimmetria di una distribuzione.

- $\gamma=0$  distribuzione simmetrica;
- $\gamma<0$  asimmetria negativa (mediana>media);
- $\gamma>0$  asimmetria positiva (mediana<media).

**Kurtosis:** indice che permette di verificare se i dati seguono una distribuzione di tipo Normale (simmetrica).

- $\beta=3$  se la distribuzione è “Normale”;
- $\beta<3$  se la distribuzione è iponormale (rispetto alla distribuzione di una Normale ha densità di frequenza minore per valori molto distanti dalla media);
- $\beta>3$  se la distribuzione è ipernormale (rispetto alla distribuzione di una Normale ha densità di frequenza maggiore per i valori molto distanti dalla media).

# IMPORTO NETTO UNITARIO

## Basic Statistical Measures

### Location

**Mean**

106.1410

**Median**

103.2900

**Mode**

0.0000

### Variability

**Std Deviation**

81.01306

**Variance**

6563


**Range**

523.69000


**Interquartile Range**

118.62500

# IMPORTO NETTO UNITARIO



# IMPORTO NETTO UNITARIO



# IMPORTO NETTO UNITARIO

## Basic Statistical Measures

### Location

**Mean**

138.0247

**Median**

129.1100

**Mode**

149.0000

### Variability

**Std Deviation**

64.29397

**Variance**

4134

**Range**

521.77000

**Interquartile Range**

82.62000