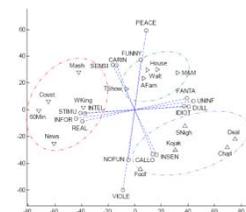


# Metodi Statistici per il Management

## Applicazioni: Marketing e Vendite

# Le previsioni in azienda

- La complessità dell'ambiente esterno, la competizione concorrenziale, la globalizzazione dei mercati impongono alle aziende di utilizzare processi decisionali supportati da proiezioni di breve e di lungo periodo.
- Le previsioni costituiscono uno dei fatti fondamentali per i processi di pianificazione aziendale. In particolare, le previsioni riguardanti le *vendite* sono alla base di scelte operate dal management relativamente a investimenti, tecnologie, assetti organizzativi e commerciali dell'impresa.
- I metodi di previsione possono essere:
  - **qualitativi**. Basati preminente su opinioni soggettive;
  - **quantitativi**. Basati su dati empirici analizzati con metodologie statistiche.

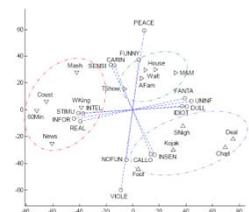




# I metodi quantitativi

I metodi quantitativi, pur con le differenze esistenti tra le molteplici tecniche, possono essere ricondotti al seguente schema logico:

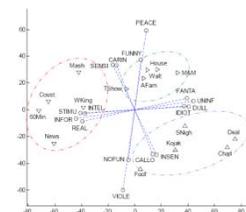
- ***input***: dati necessari per il processo di previsione;
- ***modello di analisi***: sistema o algoritmo di elaborazione dei dati di input;
- ***output***: previsioni e stime finali.



# Modelli estrapolativi e causali

Nell'ambito dei metodi quantitativi si distinguono due famiglie:

- **Modelli estrapolativi:** l'evoluzione della domanda dipende unicamente dalla variabile tempo, è quindi un fenomeno intrinseco. La previsione viene fatta basandosi unicamente sulla osservazione dei valori passati
- **Modelli causali:** l'evoluzione della domanda è collegata all'andamento futuro di variabili socioeconomiche correlate. Si tratta di individuare le variabili che sono legate alla domanda di un bene e di applicare un modello di previsione adeguato.





# Regressione lineare per dati temporali

Le osservazioni sono rilevate nel tempo. Non possiamo assumere la loro indipendenza.

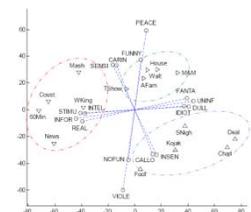
$$y_t = b_0 + b_1 x_{t1} + b_2 x_{t2} + \dots + b_k x_{tk} + w_t$$

*Equazione*

*Assunzioni*

$$E(y_t | x_{t1}, \dots, x_{tk}) = \mu_t = b_0 + b_1 x_{t1} + \dots + b_k x_{tk} \quad y_t | \mathbf{x}_t \sim N(\mu_t, \sigma_w^2), \text{ dip.}$$

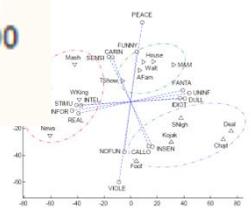
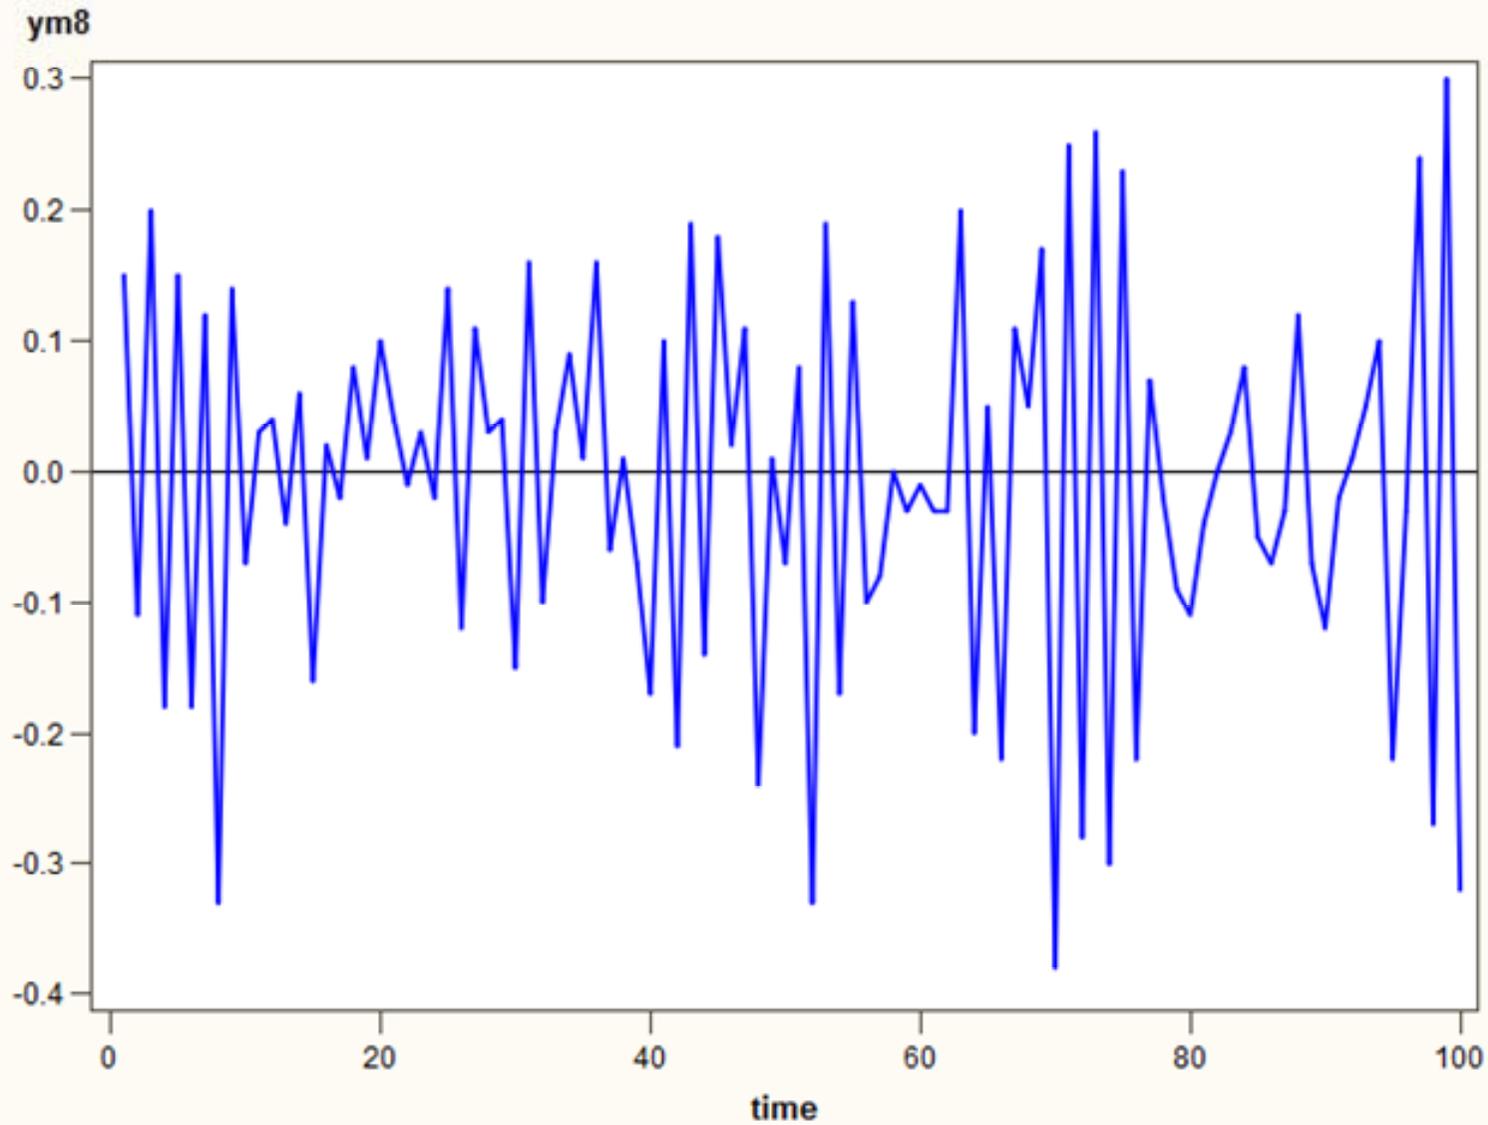
Un possibile modello per la dipendenza delle osservazioni, o equivalentemente degli errori, è il modello autoregressivo del primo ordine (AR1).







# reg: esempio AR(1)

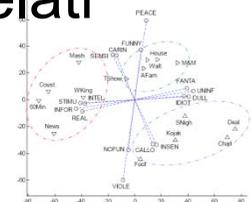


## reg: diagnostica

Al fine di capire se c'è autocorrelazione tra gli errori è utile calcolare la seguente statistica utilizzando i residui della regressione OLS

$$DW = \frac{\sum_{t=2}^n (\hat{w}_t - \hat{w}_{t-1})^2}{\sum_{t=1}^n \hat{w}_t^2} \approx 2(1 - \rho)$$

- un valore vicino a 2 indica assenza di autocorrelazione
- valori piccoli ( $\ll 2$ ) indicano che i residui successivi sono, in media, vicini in valore l'uno all'altro, o correlati positivamente
- valori grandi ( $\gg 2$ ) indicano che i residui successivi sono, in media, molto differenti in valore l'uno dall'altro, o correlati negativamente



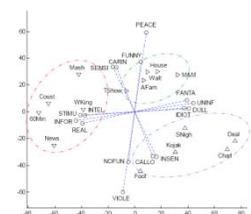
## reg: dt stima, C.I. e test

- la stima dei parametri si ottiene con il metodo della massima verosimiglianza assumendo una distribuzione normale per gli errori
- sfruttando la normalità asintotica degli stimatori di massima verosimiglianza si possono costruire intervalli di confidenza, test Z e di Wald.
- per confrontare modelli possiamo utilizzare:  
Akaike's Information criterion

$$\mathbf{AIC} = -2\log(\max \textit{likelihood}) + 2(\# \text{ parameters})$$

Bayesian Information criterion

$$\mathbf{BIC} = -2\log(\max \textit{likelihood}) + \log(n)(\# \text{ parameters})$$



# reg: esempio

Number of Observations Used	100
-----------------------------	-----

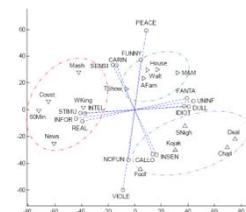
Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	2.60	2.60	35.52	<.0001
Error	98	7.18	0.07		
Corrected Total	99	9.78			

Root MSE	0.27	R-Square	0.27
Dependent Mean	1.19	Adj R-Sq	0.26
Coeff Var	22.77		

Parameter Estimates								
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr >  t	95% Confidence Limits	
Intercept	Intercept	1	0.164	0.174	0.94	0.3473	-0.181	0.510
income	income	1	0.523	0.088	5.96	<.0001	0.349	0.697

Durbin-Watson D	0.63
Number of Observations	100
1st Order Autocorrelation	0.647

$$\rho \approx 1 - \frac{DW}{2} = 1 - \frac{0,63}{2} = 0,685$$





# reg: esempio

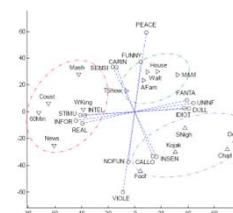
## Modello di regressione

Stime dei minimi quadrati ordinari			
SSE	7.18	DFE	98
MSE	0.07	Radice MSE	0.2707
SBC	29.63	AIC	24.41862
MAE	0.21	AICC	24.54233
MAPE	19.82	HQC	26.52734
Durbin-Watson	0.63	R-quadro regr.	0.266
		R-quadro totale	0.266

## Modello AR(1)

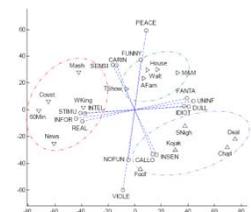
Stime della massima verosimiglianza			
SSE	3.93	DFE	97
MSE	0.04	Radice MSE	0.20123
SBC	-25.45	AIC	-33.2697
MAE	↑ 0.16	AICC	-33.0197
MAPE	15.43	HQC	-30.1066
Log verosimiglianza	19.63	R-quadro regr.	0.4964
Durbin-Watson	2.05	R-quadro totale	0.5985
		Osservazioni	100

BIC



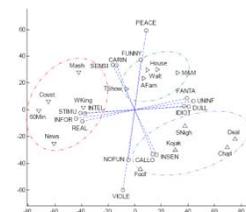
# Segmentazione concorrenza: Cluster analysis

- Con il termine **segmentazione** si intende in generale la definizione di sottoinsiemi omogenei (cluster) su un campione di  $n$  unità (clienti, competitor, prodotti, zone).
- Per **omogeneità** si intende il fatto che i cluster sono caratterizzati da elementi tra di loro vicini *simili* (vicini) rispetto ad un set di variabili di interesse.
- Gli obiettivi della segmentazione sono molteplici, in ogni caso vi è l'esigenza di ragionare e attuare strategie rispetto a  $k$  insiemi piuttosto che su un numero elevato ( $n$ ) di oggetti.

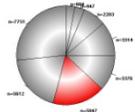


# Il caso cartaviaggio trenitalia

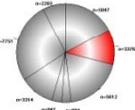
- Si analizzano le transazioni di acquisto effettuate da un campione di clienti cartaviaggio trenitalia (anno 2006) al fine di segmentare la clientela rispetto ai comportamenti di viaggio e acquisto.
- Si considerano le variabili legate alla:
  - **Spesa** (es: spesa media mensile; spesa media per ogni biglietto,...)
  - **Frequenza di viaggio e di spesa** (es: media biglietti mensili; numero biglietti;...)
  - **Tipologia di treno preferita** (es: % eurostar; %intercity; ...)
  - **Distribuzione dei viaggi nel tempo** (es: indice di omogeneità,...)
- Alle variabili si applica una cluster analysis non gerarchica (k-means) e si individuano 8 gruppi



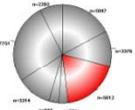
# Descrizione dei gruppi



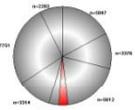
1. Occasionali Extra-comfort



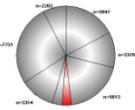
2. Gli allegri viaggiatori



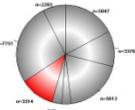
3. InterItaly solo andata



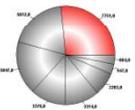
4. I fedelissimi



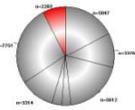
5. Occasionali lunghe tratte



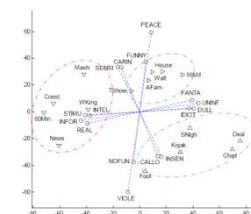
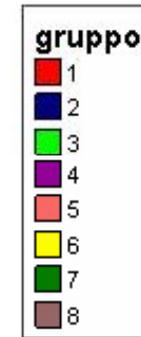
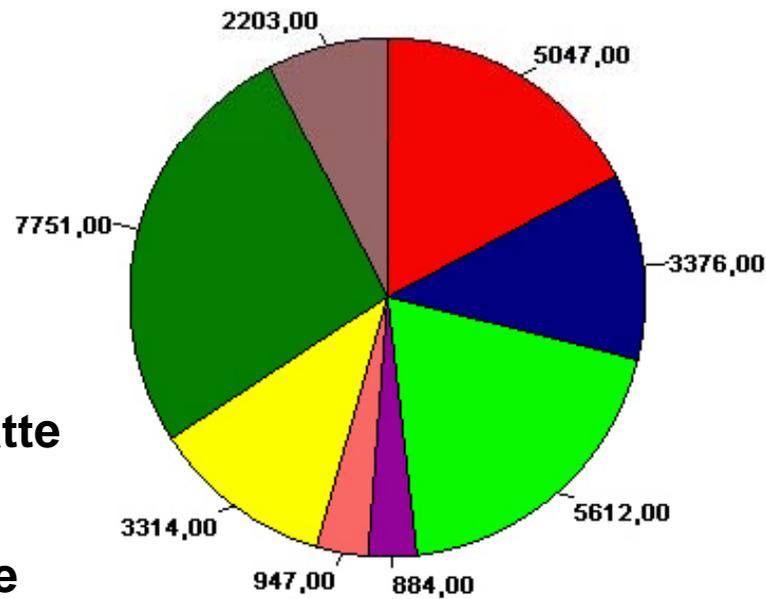
6. Occasionali brevi tratte



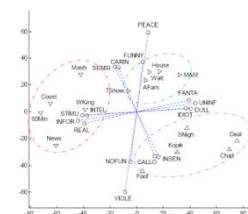
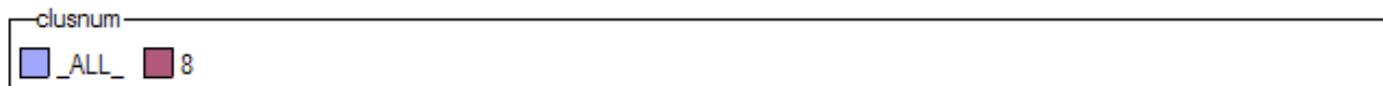
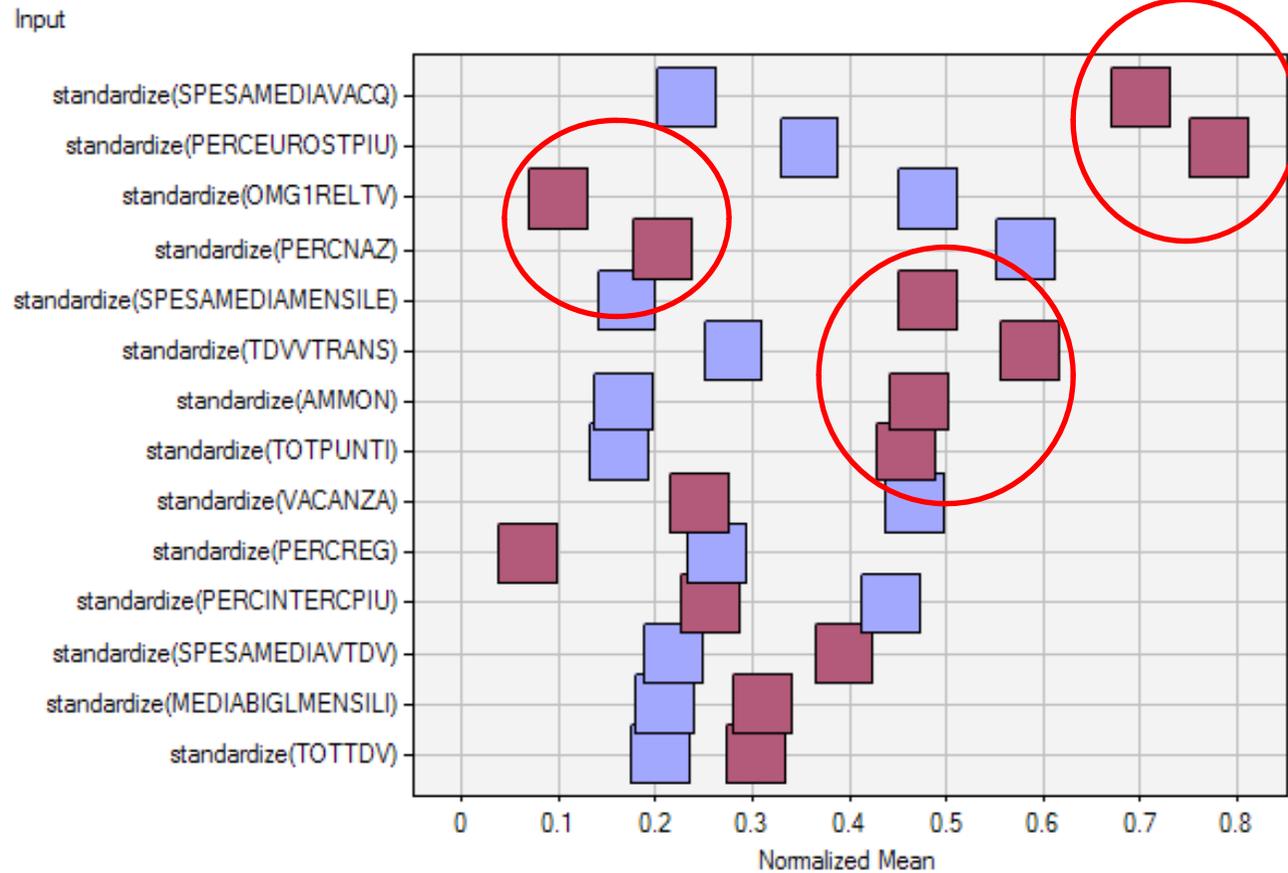
7. Gli amanti evasivi



8. I business customers

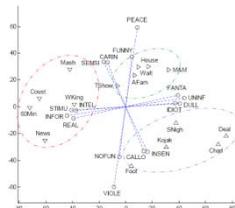
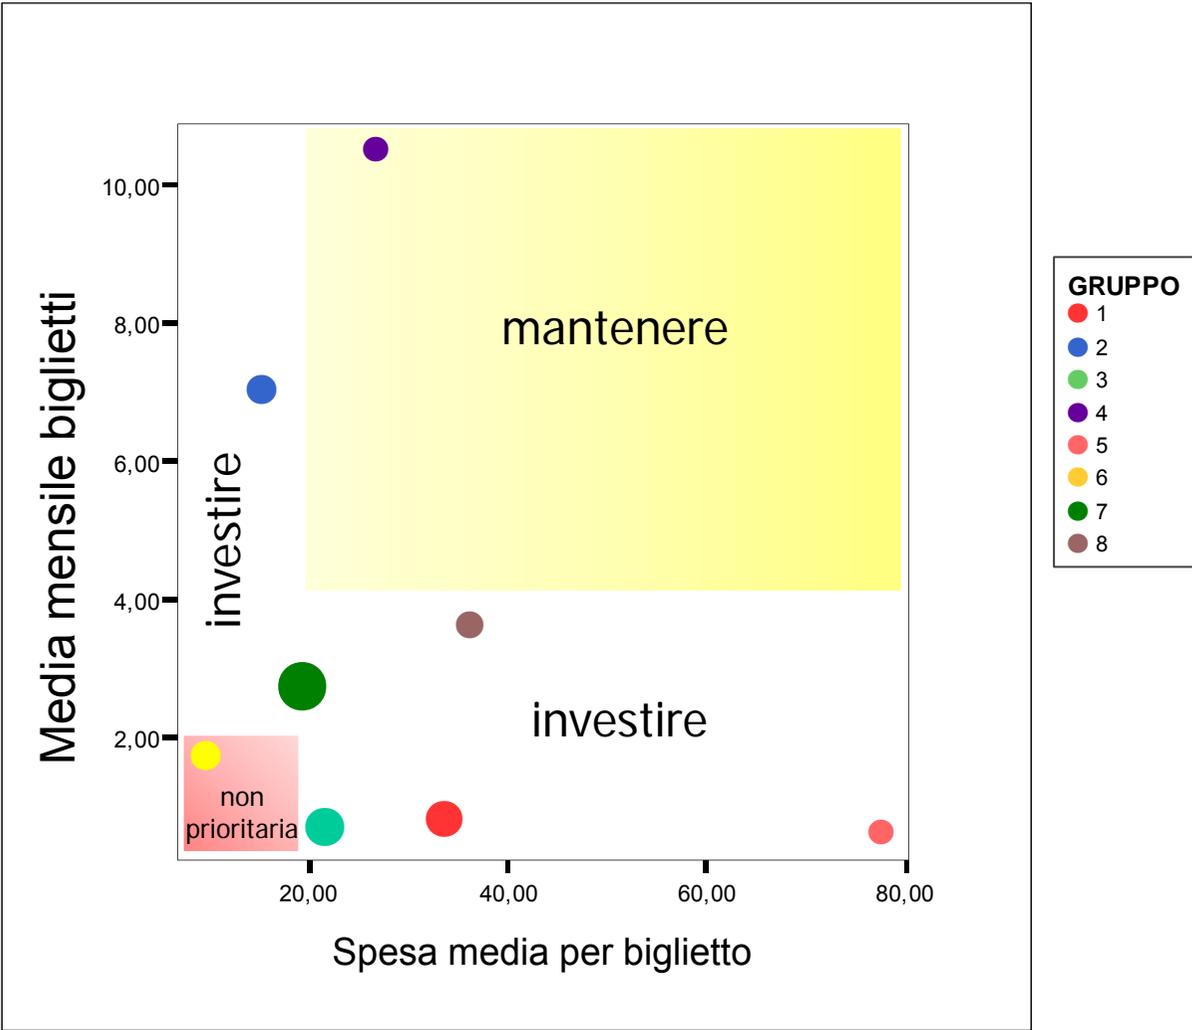


# Confronto gruppo 8 rispetto all'intero campione





# Mappatura opportunità con sovrapposizione gruppi



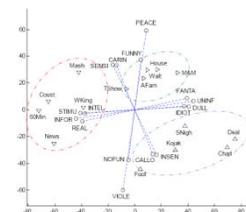
# Ricerca di mercato

Obiettivi:

- previsione delle vendite;
- analisi della soddisfazione dei clienti;
- gradimento rispetto al lancio di nuovi prodotti;
- analisi comportamenti di acquisto.

La ricerca può essere realizzata all'interno dell'azienda o commissionata ad agenzie specializzate.

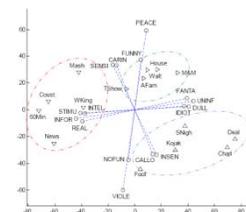
Le ricerche di mercato possono essere molto differenti in base agli obiettivi, ai budget di spesa, al settore di riferimento.





# L'elaborazione

- L'**elaborazione** è la fase più critica e importante dell'intero processo. Si tratta di trasformare *dati elementari* in *informazioni sintetiche*.
- Per **dato** si intende la singola unità informativa riferita alla singola unità: in pratica, può essere pensata come la risposta data da una persona ad una domanda.
- Per **informazione** intendiamo una sintesi di dati tramite processi di aggregazione o funzioni statistiche (somme, medie, ...).







# Strategia campionaria

Per ottenere informazioni di “buona qualità” il campione deve essere **rappresentativo**, ossia un’immagine abbastanza fedele di quegli aspetti della popolazione ritenuti rilevanti ai fini dell’indagine.

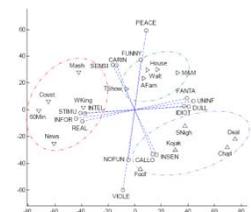
Formazione del campione: **non probabilistico – probabilistico**

## ***Non probabilistico***

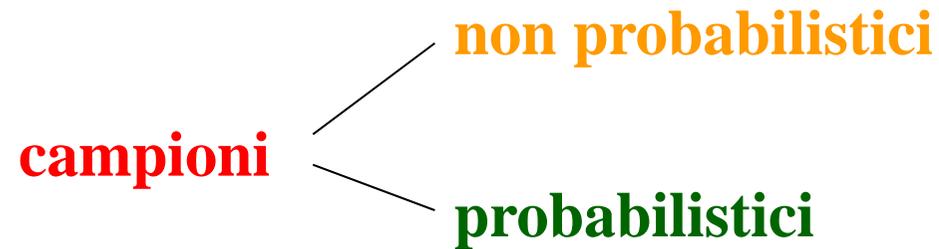
Ad esempio, selezione del campione **per quote**. La scelta dell’unità è lasciata all’operatore e la dimensione del campione è fissata con criteri di convenienza.

## ***Probabilistico***

Equivale all’estrazione da un’urna di un certo numero di palline secondo una strategia o *piano di campionamento* che assegna una probabilità di estrazione ad ogni campione.



# Strategia campionaria

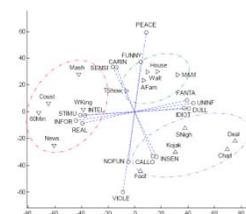


## Campioni non probabilistici

- 1) A scelta ragionata
- 2) Per quote
- 3) Tramite testimoni privilegiati

## Campioni probabilistici

- 1) Semplici con o senza ripetizione
- 2) Stratificato
- 3) A grappoli
- 4) Sistemático
- 5) A due stadi

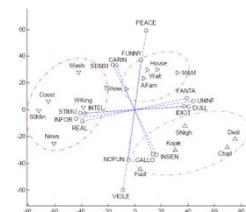


# Strategia campionaria

Il campionamento **non probabilistico** non fornisce a ciascuna unità della popolazione la stessa possibilità di far parte del campione, pertanto alcune unità statistiche hanno maggiore probabilità di essere estratte dalla popolazione.

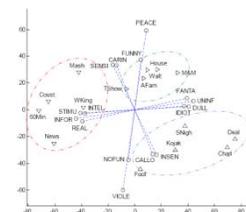
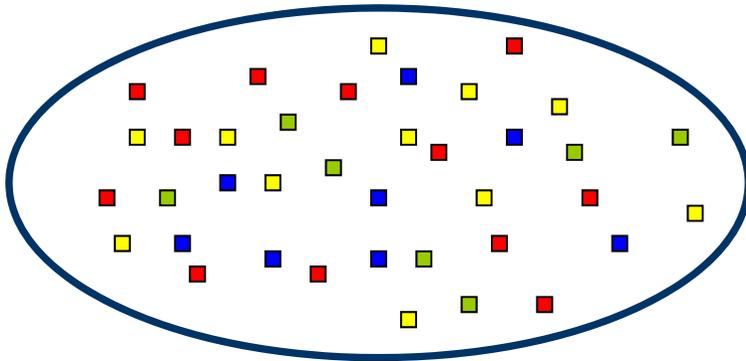
Questo metodo prevede l'estrazione del campione in base a **criteri di comodo o di praticità**: per esempio perché le unità da campionare sono più facilmente accessibili, o per ragioni di costo, o perché in una certa zona sono disponibili volontari ecc.

Un campione selezionato con questi criteri di comodo, sebbene abbia il vantaggio della rapidità, è soggetto ad un forte *bias*, fornisce dati poco affidabili e può essere facilmente viziato da errori sistematici.



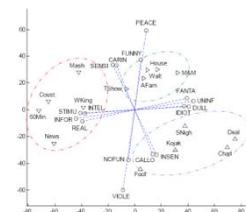
# Strategia campionaria

Mentre il campione non probabilistico pretende di essere rappresentativo, il campione probabilistico non ha simili pretese; esso è soltanto uno fra i possibili campioni estraibili dalla popolazione. Il vantaggio che presenta è, oltre all'eliminazione di un soggettivismo rischioso, nella possibilità di costruire un modello matematico per porre su basi razionali la scelta tra varie strategie possibili. La **teoria dei campioni** permette di valutare l'attendibilità dei risultati.



# Campionamento probabilistico

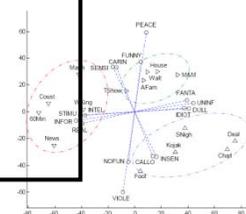
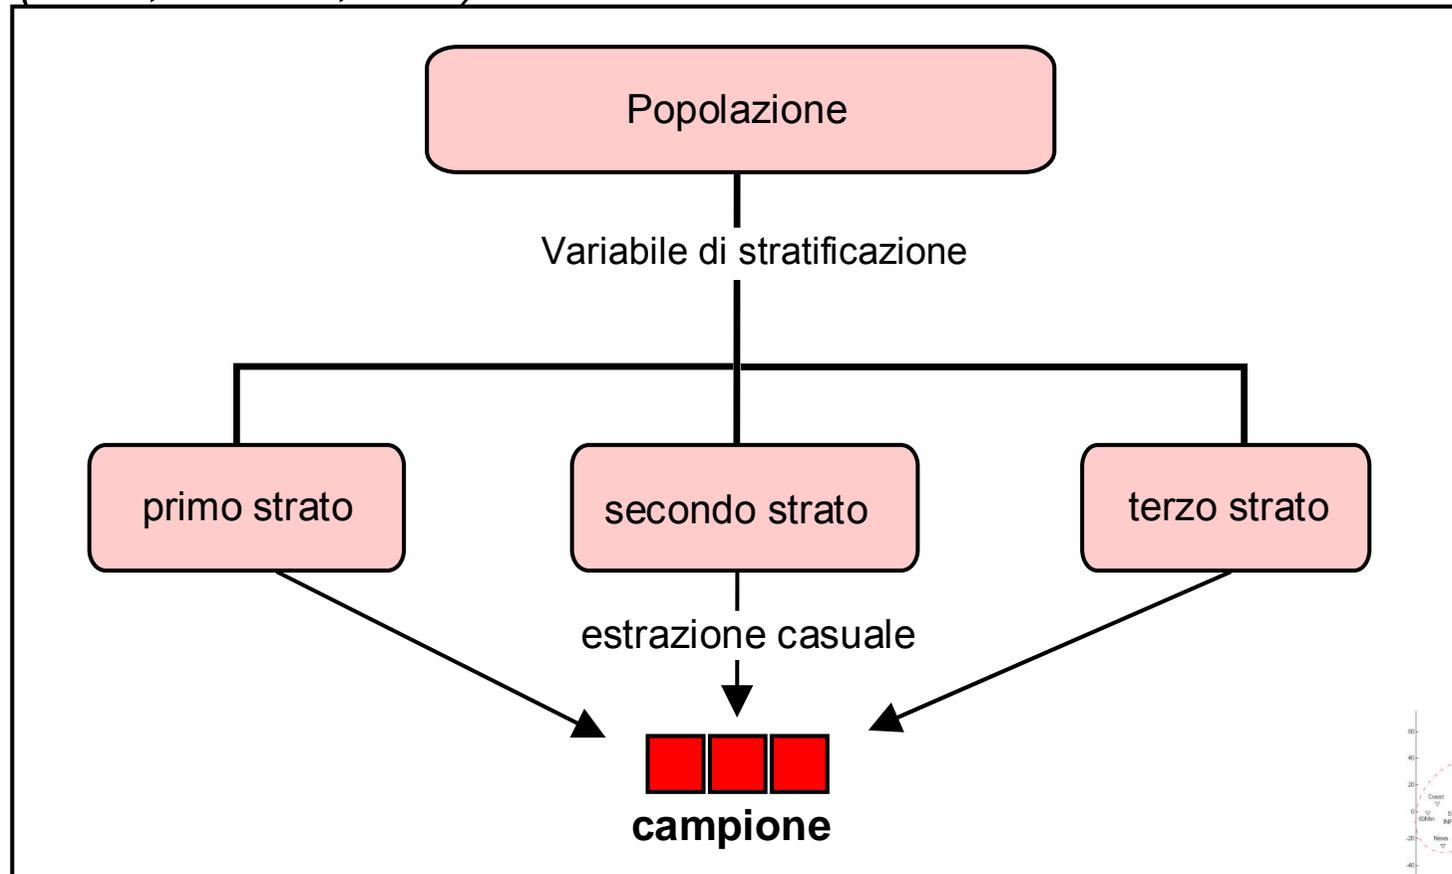
- ➔ **Campionamento casuale:** insieme di tutte quelle tecniche di formazione del campione in cui la selezione delle unità è affidata a regole probabilistiche.
- ➔ **Campionamento casuale **semplice**:** i campioni della stessa dimensione estraibili da una popolazione hanno uguale probabilità di essere estratti.
- ➔ **Campionamento casuale **stratificato**:** la popolazione viene suddivisa in un certo numero di strati. Da ogni strato in maniera indipendente viene poi estratto un campione casuale semplice.





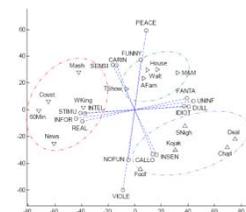
# Campionamento casuale stratificato

Nel **campionamento casuale stratificato** la popolazione viene suddivisa in **strati**. Da ogni strato vengono poi estratti, tramite un campionamento casuale semplice, le unità da inserire nel campione. *Esempio di variabile di stratificazione: Ripartizione territoriale con tre strati (Nord, Centro, Sud).*



# Vantaggi nell'uso del campione casuale stratificato rispetto a quello semplice

- ❖ Se sussiste una relazione fra la variabile di stratificazione e la variabile da stimare, l'operazione di stratificazione aumenta la **rappresentatività del campione**
- ❖ **Miglioramento della stima**, se gli strati sono stati ben scelti. (si riduce la variabilità dello stimatore ossia si aumenta la precisione)
- ❖ Possibilità di ottenere anche le **stime per le singole sottopopolazioni** o strati.



# Come estrarre le unità dagli strati?

Il campionamento stratificato assicura la presenza nel campione di unità provenienti da ogni sub-popolazione (strato)

- Se la variabilità della Y all'interno degli L strati non si differenzia, si procede al **campionamento a frazione di sondaggio costante**, dove i campioni estratti in ogni strato risultano proporzionali alle rispettive sub-popolazioni (piano auto-ponderante)

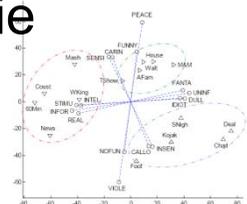
- Se la variabilità all'interno degli L strati si differenzia molto, si procede al **campionamento a frazione di sondaggio variabile**, che riduce la numerosità campionaria per gli strati con minore variabilità e l'aumenta a quelli più variabili

## Problemi

Scelta degli strati; La numerosità campionaria di ogni strato

## Vantaggi

Il guadagno in efficienza aumenta quanto più differiscono le medie della Y riferite ai singoli strati (ANOVA)



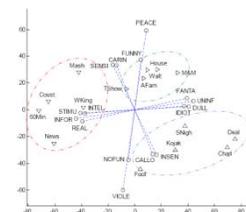
# Stimatore della media attraverso il campione casuale stratificato

	Strato 1	Strato 2	.....	Strato L	Totale
Popolazione	$N_1$	$N_2$	.....	$N_L$	$N$
	$\sigma_1^2$	$\sigma_2^2$		$\sigma_L^2$	$\sigma^2$
Campione	$n_1$	$n_2$	.....	$n_L$	$n$
	$\bar{Y}_1$	$\bar{Y}_2$		$\bar{Y}_L$	$\bar{Y}$

## Stimatore corretto ed efficiente della media (Pop. Finita)

$$\bar{Y}_{st} = \sum_{h=1}^L w_h \bar{Y}_h \quad \text{dove } w_h = N_h/N$$

$$Var(\bar{Y}_{st}) = \sum_h w_h^2 (1 - f_h) \frac{\sigma_h^2}{n_h} \quad \text{dove } f_h = \frac{n_h}{N_h}$$





# Esempio: Spesa media annuale dei possessori di CartaViaggio di Trenitalia

## I parametri ignoti della popolazione

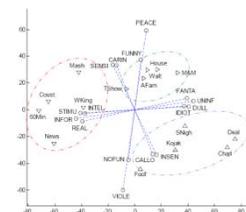
$N=29.206$  clienti (in realtà è il 10% della Popolazione)

$\mu =$  Spesa Media = 509

$\sigma^2 =$  Varianza della spesa = 367918

$\sigma =$  Deviazione standard = 607

	Imp	Dip	Noccup
<b>Dim. <math>N_h</math></b>	<b>7136</b>	<b>14654</b>	<b>7416</b>
<b>%</b>	<b>24,4</b>	<b>50,2</b>	<b>25,4</b>
<b>media</b>	<b>642</b>	<b>525</b>	<b>350</b>
<b>varianza</b>	<b>454996</b>	<b>427191</b>	<b>124334</b>
<b>Dev. Stand.</b>	<b>675</b>	<b>654</b>	<b>353</b>



## Esempio: Spesa media annuale dei possessori di CartaViaggio di Trenitalia

1° caso: Camp. Casuale semplice (0,5%)

$$f = n/N = 1455/29206 = 0,05$$

$$e \quad n=1455$$

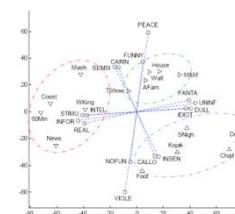
$$\hat{y} = \sum_{i=1}^n y_i = \boxed{521}$$

Stime del campione		
Media	Varianza	Dev.Stand.
521	486093	697

**Varianza dello stimatore**  $V(\hat{y}) = \frac{(1-f)}{n} \sigma^2 = \frac{0,95}{1455} 367918 = \boxed{240}$

**Stima della varianza**  $v(\hat{y}) = \frac{(1-f)}{n} s^2 = \frac{0,95}{1455} 486093 = 317$

**Stima dell'errore standard**  $e.r.(\hat{y}) = \sqrt{v(\hat{y})} = 17,8$



## 2° caso: Camp. stratificato con allocazione proporzionale

$$f = n/N = 1455/29206 = 0,05$$

$$\text{e } n=1455$$

Stime del campione

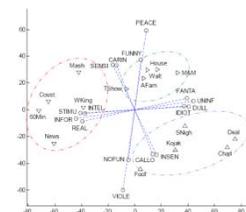
L	Imp	Dip	Noccup
Dim. $N_h$	7136	14654	7416
$W_h$	0,244	0,502	0,254
$n_h$	356	730	369
media	632	558	321
varianza	371148	341479	92033
Dev.stand.	609.2	584.4	303.4

$$\hat{y}_{str} = \sum_{h=1}^L w_h \hat{y}_h = \sum_{h=1}^L \frac{N_h}{N} \hat{y}_h = 516$$

$$V(\hat{y}_{str}) = \sum_{h=1}^L w_h^2 V(\hat{y}_h) = \sum_{h=1}^L w_h^2 \frac{(1-f_h)}{n_h} \sigma_h^2 = 233$$

$$v(\hat{y}_{str}) = \sum_{h=1}^L w_h^2 v(\hat{y}_h) = \sum_{h=1}^L w_h^2 \frac{(1-f_h)}{n_h} s_h^2 = 186$$

**Stima dell'errore standard**  $e.r.(\hat{y}_{st}) = \sqrt{v(\hat{y}_{st})} = 13,6$



# Confronto

Confronto					
			Int. Conf. 95%		
	Stima	Err. Stand.	Estr. Inf.	Estr. Sup.	Amp.
Camp.cas. SEMPL.	521	17,8	486,1	555,9	69,8
Camp. Cas. STR.	516	13,6	489,3	542,7	53,3
Popolazione	media	509			

- Gli strati ottenuti dalla variabile di stratificazione individuano livelli medi di spesa diversi
- La stima ottenuta dal campione casuale stratificato è più efficiente di quella ottenuta dal campione casuale semplice
- Si ottiene un intervallo di confidenza più piccolo a parità di livello di confidenza.

