

# Metodi Quantitativi per Economia, Finanza e Management

## *Lezione n°5*

Analisi Bivariata I° Parte

# Statistica descrittiva bivariata

Indaga la relazione tra due variabili misurate. Si distingue rispetto alla tipologia delle variabili indagate:

- **var. qualitative/quantitative discrete**: tavole di contingenza (o a doppia entrata)
- **var. quantitative**: analisi di correlazione lineare
- **una var. qualitativa e una quantitativa**: confronto tra le medie

# Tavole di contingenza

Sono tabelle a doppia entrata; i valori riportati all'interno della tabella sono le frequenze congiunte assolute, e la loro somma è pari al totale dei casi osservati.

Dalla tabella si possono ricavare inoltre le distribuzioni marginali, sommando per riga e per colonna le frequenze congiunte; le frequenze relative congiunte, pari al rapporto tra le frequenze assolute congiunte e il totale dei casi osservati.

Sesso \* Età Crosstabulation

			Età				Total
			18-25	26-35	36-50	Over 50	
Sesso	M	Count	25	22	22	17	86
		% within Sesso	29.1%	25.6%	25.6%	19.8%	100.0%
		% within Età	32.1%	40.0%	53.7%	36.2%	38.9%
		% of Total	11.3%	10.0%	10.0%	7.7%	38.9%
F	F	Count	53	33	19	30	135
		% within Sesso	39.3%	24.4%	14.1%	22.2%	100.0%
		% within Età	67.9%	60.0%	46.3%	63.8%	61.1%
		% of Total	24.0%	14.9%	8.6%	13.6%	61.1%
Total	Total	Count	78	55	41	47	221
		% within Sesso	35.3%	24.9%	18.6%	21.3%	100.0%
		% within Età	100.0%	100.0%	100.0%	100.0%	100.0%
		% of Total	35.3%	24.9%	18.6%	21.3%	100.0%

# Tavole di contingenza

Dalle tabelle di contingenza si possono ricavare ulteriori distribuzioni unidimensionali :

- *Frequenze subordinate* ovvero la frequenza di osservare il carattere  $x$  dato il carattere  $y$  e viceversa. Formalmente:

$$P_{y|x}(x_i, y_j) = P(x_i, y_j) / P_x(x_i)$$

$$P_{x|y}(x_i, y_j) = P(x_i, y_j) / P_y(y_j)$$

*Indipendenza statistica* se al variare di  $X$  le distribuzioni subordinate  $(Y|X) = x_i$  sono tutte uguali tra loro, si può concludere che la distribuzione del carattere  $Y$  non dipende da  $X$ . Nel caso di indipendenza statistica, la frequenza relativa congiunta è pari al prodotto delle marginali corrispondenti

$$P(x_i, y_j) = P_x(x_i)P_y(y_j)$$

L'indipendenza stat. è un concetto simmetrico: se vale per  $X$ , vale anche per  $Y$ . Se si verifica, vuol dire che l'analisi bivariata di  $X$  ( $Y$ ) non dà informazioni aggiuntive rispetto all'analisi univariata.

# Tavole di contingenza

- *Perfetta dipendenza unilaterale* ad ogni valore di X corrisponde un solo valore di Y, ma non è detto che si verifichi il contrario. In generale, quando il numero di colonne (valori assunti dalla Y) è inferiore al numero di righe (valori assunti dalla X) non è mai possibile che X dipenda perfettamente da Y.
- *Perfetta dipendenza bilaterale* ad ogni valore di X corrisponde un solo valore di Y e viceversa; la perfetta dipendenza bilaterale si può avere allora solo per matrici quadrate.

# Indici di connessione

Nella realtà è difficile che si verifichi la condizione di indipendenza statistica. Pertanto è utile disporre di indici che misurino il grado di connessione tra le variabili.

- $\chi^2$  (chi-quadrato) assume valore nullo se i fenomeni X e Y sono indipendenti. Risente del numero delle osservazioni effettuate quindi al crescere di N, l'indice tende a crescere.

$$\chi^2 = N \sum \sum [P(x_i, y_j) - P_x(x_i) P_y(y_j)]^2 / P_x(x_i) P_y(y_j)$$

**Chi-Square Tests**

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	5.471 <sup>a</sup>	3	.140
Likelihood Ratio	5.402	3	.145
N of Valid Cases	221		

a. 0 cells (.0%) have expected count less than 5. The minimum expected count is 15.95.

# Indici di connessione

- Un indice più efficace (perchè relativo, e dunque non risente del numero di osservazioni) è **l'indice di Cramer V**, basato sul  $\chi^2$ . assume valori compresi tra 0 e 1: 0 nel caso di indipendenza statistica, 1 nel caso di perfetta dipendenza almeno unilaterale e tende a crescere all'aumentare del grado di dipendenza delle variabili considerate.

**Symmetric Measures**

		Value	Approx. Sig.
Nominal by	Phi	.157	.140
Nominal	Cramer's V	.157	.140
N of Valid Cases		221	

- Not assuming the null hypothesis.
- Using the asymptotic standard error assuming the null hypothesis.

# Indici di connessione

Nella realtà è difficile che si verifichi la condizione di indipendenza statistica. Pertanto è utile disporre di indici che misurino il grado di connessione tra le variabili.

- $\chi^2$  (chi-quadrato) assume valore nullo se i fenomeni X e Y sono indipendenti. Risente del numero delle osservazioni effettuate quindi al crescere di N, l'indice tende a crescere.

$$\chi^2 = N \sum \sum [P(x_i, y_j) - P_x(x_i) P_y(y_j)]^2 / P_x(x_i) P_y(y_j)$$

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	5.471 <sup>a</sup>	3	.140
Likelihood Ratio	5.402	3	.145
N of Valid Cases	221		

a. 0 cells (.0%) have expected count less than 5. The minimum expected count is 15.95.



# Indici di connessione

- Un indice più efficace (perchè relativo, e dunque non risente del numero di osservazioni) è l'indice di Cramer V, basato sul  $\chi^2$ . assume valori compresi tra 0 e 1: 0 nel caso di indipendenza statistica, 1 nel caso di perfetta dipendenza almeno unilaterale e tende a crescere all'aumentare del grado di dipendenza delle variabili considerate.

Symmetric Measures

		Value	Approx. Sig.
Nominal by	Phi	.157	.140
Nominal	Cramer's V	.157	.140
N of Valid Cases		221	

- Not assuming the null hypothesis.
- Using the asymptotic standard error assuming the null hypothesis.