

Appunti di Probabilità e Statistica

Gianluca Orlando

Versione: 22 febbraio 2025

Prefazione

Un disclaimer su questi appunti. Questo non è un libro di testo. Come si dovrebbe fare per qualunque esame, gli argomenti del corso dovrebbero essere studiati dai libri di testo consigliati. Questi, infatti, sono stati scritti da esperti, selezionando argomenti ed esercizi, sono stati sottoposti a revisione da parte di altri esperti, editi molte volte ed utilizzati in svariati corsi universitari in tutto il mondo. I libri consigliati sono [1, 4, 6]. La parte di statistica descrittiva di questo corso è presa da [6]. La parte di probabilità di questo corso è presa da [1, 6]. La parte di statistica inferenziale è presa da [1, 6, 4]. Per chi non ha problemi con l'inglese, si consiglia la versione inglese dei testi [5, 3].

Questi sono solamente degli appunti personali del docente del corso, scritti velocemente, non revisionati. Sono utilizzati come riferimento per insegnare il corso di “Probabilità e Statistica” del corso di studi in Ingegneria Gestionale al Politecnico di Bari.

Occorre fare una precisazione: il corso non è da identificare con la materia insegnata. Il corso è una breve panoramica di alcuni argomenti importanti, presentati con il punto di vista del docente.



FIGURA 0.1. A sinistra: Blaise Pascal (1623-1662).^a Al centro: Pierre de Fermat (1601-1665).^b A destra: Christiaan Huygens (1629-1695).^c Tra i primi ad occuparsi di probabilità e statistica.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Blaise_Pascal_Versailles.JPG.

^bFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Pierre_de_Fermat.jpg.

^cFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Christiaan_Huygens-paintin g.jpeg.

Personae. Negli appunti sono presenti le foto di alcune persone che hanno contribuito allo sviluppo della statistica e della probabilità. Sicuramente ci sono molte persone che non

sono state inserite. Per approfondire la storia degli argomenti di statistica e di probabilità si può consultare il libro [2].




FIGURA 0.2. *xkcd* 2582. DATA TRAP. Credits: <https://xkcd.com/2582/>

xkcd. Negli appunti sono inserite delle vignette come la Figura 0.2. Sono tratte da un webcomic chiamato *xkcd* creato da Randall Munroe. Munroe è laureato alla Christopher Newport University e ha lavorato come consulente per la NASA. Per ogni vignetta vengono descritti il titolo e il link alla pagina originale (in inglese). Si spera che le vignette di Munroe facciano ridere anche chi si troverà tra le mani questi appunti. Se si riesce a ridere di argomenti “noiosi” come quelli coperti da un corso tecnico, vuol dire che gli argomenti sono stati assimilati ancora meglio.

Ordine. Gli argomenti di questi appunti non sono nell’ordine presentato a lezione. Sono ordinati in modo che gli strumenti necessari per le spiegazioni siano sempre a disposizione. A lezione, invece, gli argomenti sono presentati in modo da introdurre gli ingredienti quando sono necessari. Ad esempio, a lezione vengono forniti alcuni esempi di leggi discrete e continue prima di alcuni argomenti trattati nel capitolo sulle variabili aleatorie.

Errori. Questi appunti conterranno certamente tantissimi errori. Chiedo gentilmente di segnalarli inviando un’email all’indirizzo gianluca.orlando@poliba.it.

Indice

Prefazione	i
Capitolo 1. Statistica descrittiva	3
1.1. Concetti di base della statistica	3
1.2. Frequenze, tabelle e grafici	6
1.3. Moda e classi modali	15
1.4. Media	16
1.5. Varianza e deviazione standard	19
1.6. Quartili, percentili, quantili	22
1.7. Regressione lineare	29
Capitolo 2. Probabilità	41
2.1. Spazi di probabilità, primi esempi e prime proprietà	41
2.2. Enumerazione	56
2.3. Probabilità condizionata ed eventi indipendenti	63
Capitolo 3. Variabili aleatorie	79
3.1. Variabili aleatorie	79
3.2. Variabili aleatorie discrete	84
3.3. Vettori aleatori	85
3.4. Vettori aleatori discreti con due componenti	87
3.5. Valore atteso per variabili aleatorie discrete	89
3.6. Variabili aleatorie assolutamente continue	91
3.7. Vettori aleatori assolutamente continui con due componenti	93
3.8. Valore atteso per variabili aleatorie assolutamente continue	96
3.9. Varianza, deviazione standard e covarianza per variabili aleatorie discrete	101
Capitolo 4. Leggi discrete	109
4.1. Legge di Bernoulli	109
4.2. Legge binomiale	110
4.3. Legge di Poisson	117
4.4. Legge geometrica	122
Capitolo 5. Leggi continue	129
5.1. Legge uniforme	129
5.2. Legge normale	131
5.3. Legge esponenziale	137
5.4. Legge Gamma	141

5.5. Legge chi-quadro	146
5.6. Legge t-Student	147
Capitolo 6. Statistica inferenziale	151
6.1. Statistiche e stimatori	151
6.2. Alcune leggi importanti	156
6.3. Teoremi limite	159
Capitolo 7. Intervalli di confidenza	165
7.1. Definizioni di intervalli di confidenza	165
7.2. Calcolo di intervalli di confidenza	167
Capitolo 8. Test di ipotesi	183
8.1. Introduzione e definizioni	183
8.2. Impostazione di un test di ipotesi	188
8.3. Esempi di test di ipotesi	189
Appendice A. Schema riassuntivo delle variabili aleatorie	225
A.1. Legge di Bernoulli	226
A.2. Legge binomiale	227
A.3. Legge di Poisson	228
A.4. Legge geometrica	229
A.5. Legge uniforme	230
A.6. Legge normale	231
A.7. Legge esponenziale	232
A.8. Legge Gamma	233
A.9. Legge chi-quadro	234
A.10. Legge t-Student	235
Appendice. Lista dei simboli	237
Legenda	237
Simboli matematici	237
Appendice. Bibliografia	239

CAPITOLO 1

Statistica descrittiva

Contenuti

1.1. Concetti di base della statistica	3
Popolazione	3
Campione	4
Variabili/Caratteri e Valori/Modalità	5
Dati	5
1.2. Frequenze, tabelle e grafici	6
1.3. Moda e classi modali	15
1.4. Media	16
1.5. Varianza e deviazione standard	19
1.6. Quartili, percentili, quantili	22
1.6.1. Quartili	22
1.6.2. Percentili	25
1.6.3. Quantili	25
1.6.4. Approssimazione dei quantili per dati raggruppati in classi	26
1.6.5. Dati anomali e sospetti	27
1.6.6. Box-plot	28
1.7. Regressione lineare	29
Scatterplot	29

1.1. Concetti di base della statistica

Popolazione. L'obiettivo della statistica è quello di ottenere informazioni su una *popolazione*. Una *popolazione* è un insieme di elementi.

⚠ Il termine “popolazione” è da intendersi *lato sensu*, ovvero non identifica necessariamente una popolazione costituita da individui.

ESEMPIO 1.1. Alcuni esempi di popolazioni:

- cittadini e cittadine residenti in uno stato;
- studenti e studentesse del Politecnico di Bari;
- animali allevati in Italia;
- ulivi in Puglia;
- dispositivi prodotti da un'azienda.

□

La statistica entra in gioco nel momento in cui la popolazione è troppo numerosa per poter esaminare ogni singolo elemento della popolazione.



FIGURA 1.1. *xkcd* 1827. SURVIVORSHIP BIAS. Credits: <https://xkcd.com/1827/>

Campione. Un *campione* è un sottoinsieme della popolazione in esame. Lo scopo della statistica è quello di:

- (1) descrivere il campione;
- (2) fare inferenza statistica sull'intera popolazione.

Nella prima parte del corso ci occuperemo della *statistica descrittiva*, che si occupa della descrizione del campione. La statistica inferenziale richiede tecniche più avanzate di probabilità e verrà trattata nella terza e ultima parte del corso.

⚠ Poiché si vogliono generalizzare le informazioni acquisite sul campione all'intera popolazione, è importante evitare il rischio di un *bias* (distorsione) nel momento in cui viene scelto il campione da chi esegue lo studio statistico. Il campione deve essere il più possibile rappresentativo della popolazione.

ESEMPIO 1.2. Si vuole studiare l'età di una popolazione costituita dai residenti in una città. Si analizza un campione di 100 individui che frequentano la biblioteca della città. L'età media risulta essere 46. Ci potrebbe essere un rischio di *bias*: il campione è stato selezionato in un'area specifica e potrebbe non essere rappresentativo della popolazione (ad esempio, la biblioteca potrebbe essere frequentata da più persone giovani o anziane rispetto a persone in età lavorativa). □

ESEMPIO 1.3. Si vuole effettuare un'analisi economica. Viene esaminato un campione di aziende in attività. A seconda del tipo di analisi che si vuole effettuare, ci potrebbe

essere un rischio di *bias*: non vengono considerate le aziende che hanno fallito. Questo tipo di distorsione è nota come *survivorship bias*. \square

Variabili/Caratteri e Valori/Modalità. Per *variabile* o *carattere* si intende una caratteristica degli elementi della popolazione che viene esaminata con l'indagine statistica.¹ Ogni variabile può assumere diversi *valori* o *modalità*. Le variabili vengono distinte in:

- *variabili quantitative*: descrivono una quantità associata agli individui della popolazione. Assumono valori numerici. A loro volta, vengono distinte in:
 - *discrete*: se l'insieme dei valori numerici che possono essere assunti è costituito da un insieme discreto di numeri (es.: $\{1, 2, 3, 4, 5, \dots\}$);
 - *continue*: se l'insieme dei valori numerici che possono essere assunti è costituito da un insieme continuo (es.: \mathbb{R}).
- *variabili qualitative*: descrivono una qualità associata agli individui della popolazione. Non assumono valori numerici (es.: aggettivi, giorni della settimana).

ESEMPIO 1.4. Consideriamo il seguente studio statistico:

- Popolazione: studenti e studentesse del corso “Probabilità e Statistica”.
- Campione: iscritti/e all'appello di giugno 2024.
- Variabile: voto.

Questa variabile è quantitativa discreta poiché l'insieme dei valori che possono essere assunti dai voti è costituito da $\{0, 18, 19, 20, \dots, 30, 31\}$. \square

ESEMPIO 1.5. Consideriamo il seguente studio statistico:

- Popolazione: Stazioni di rifornimento nella provincia di Bari.
- Campione: 20 stazioni di rifornimento scelte in modo uniforme sul territorio.
- Variabile: prezzo del gasolio.

Questa variabile è quantitativa continua poiché l'insieme dei valori che possono essere assunti dal prezzo della benzina è costituito dall'intervallo $(0, +\infty)$. \square

ESEMPIO 1.6. Consideriamo il seguente studio statistico:

- Popolazione: giovani tra i 20 e i 25 anni.
- Campione: 100 persone scelte da un campus universitario.
- Variabile: *social network* più utilizzato.

Questa variabile è qualitativa. L'insieme dei valori che possono essere assunti è costituito da $\{\text{Instagram, TikTok, Facebook, X, Threads, } \dots\}$ \square

Dati. I *dati* di un campione sono i valori assunti dalle variabili esaminate osservati e raccolti dall'indagine statistica. Tipicamente, i dati raccolti sono *grezzi* e difficili da interpretare.

Gli obiettivi della statistica descrittiva sono:

¹In questo corso utilizzeremo il termine *variabile*. Nella parte finale del corso sulla statistica inferenziale, quando avremo gli strumenti adeguati di probabilità, forniremo una definizione rigorosa di variabile di una popolazione e di campione. Per ora ci accontenteremo di queste definizioni non rigorose per poter introdurre gli argomenti.

- (1) Rappresentare i dati, utilizzando tabelle e grafici che evidenzino alcuni aspetti delle variabili in esame.
- (2) Analizzare i dati, determinando delle grandezze adeguate che possano sintetizzare i dati.

Vedremo vari esempi di dati durante il corso.

1.2. Frequenze, tabelle e grafici

Introduciamo il concetto di frequenza per raccogliere i dati in base al numero di volte in cui i valori vengono assunti.

DEFINIZIONE 1.7. (Frequenze per variabili qualitative o quantitative discrete.) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (qualitativa o quantitativa discreta). Siano v_1, \dots, v_k i valori distinti assunti dalla variabile in esame.² Le *frequenze assolute* dei valori v_1, \dots, v_k sono i numeri $f_1, \dots, f_k \in \{0, 1, \dots, n\}$ definiti da

$$f_j := \#\{i \in \{1, \dots, n\} \text{ tale che } x_i = v_j\}.$$

Le *frequenze relative* sono i numeri $p_1, \dots, p_k \in [0, 1]$ definiti da

$$p_j := \frac{f_j}{n}.$$

□

OSSERVAZIONE 1.8. Dalla definizione si ha direttamente che

$$\sum_{j=1}^k f_j = n, \quad \sum_{j=1}^k p_j = 1 = 100\%.$$

□

Le frequenze possono essere riassunte in tabelle con le strutture illustrate in Tabella 1 e Tabella 2.

valori	frequenze assolute
v_1	f_1
\vdots	\vdots
v_k	f_k

TABELLA 1. Struttura di una tabella delle frequenze assolute.

valori	frequenze relative
v_1	p_1
\vdots	\vdots
v_k	p_k

TABELLA 2. Struttura di una tabella delle frequenze relative.

²Attenzione: k è, in generale, diverso da n poiché un valore può essere assunto più di una volta.

Le frequenze assolute e relative possono essere rappresentate graficamente in un *diagramma a barre*. Si veda la Figura 1.2 e la Figura 1.2 per la struttura di tale grafico.




FIGURA 1.2. Struttura di un diagramma a barre delle frequenze assolute.




FIGURA 1.3. Struttura di un diagramma a barre delle frequenze relative.

OSSERVAZIONE 1.9. Per lo stesso set di dati, il diagramma a barre delle frequenze relative ha lo stesso aspetto del diagramma a barre delle frequenze assolute, a meno di riscalare l'asse verticale, si confrontino la Figura 1.2 e la Figura 1.2. \square

OSSERVAZIONE 1.10. In un diagramma a barre, tipicamente, l'ordine dei valori non è rilevante, in particolare se la variabile in esame è qualitativa. Per evidenziare questa caratteristica, le barre vengono rappresentate distanziate l'una dall'altra. Ad esempio il diagramma a barre in Figura 1.2 può essere riorganizzato come in Figura 1.2. \square

Un diagramma a barre in cui i valori assunti sono ordinati in modo che le frequenze (assolute o relative) siano decrescenti viene detto *diagramma di Pareto*.




FIGURA 1.4. È possibile riordinare le barre in un diagramma a barre. Il risultato è un diagramma di Pareto.

Un ulteriore grafico per rappresentare le frequenze (tipicamente quelle relative) è il diagramma a torta.




FIGURA 1.5. Esempio di un diagramma a torta.

ESEMPIO 1.11. I dati seguenti indicano il gruppo sanguigno di 50 donatori in un centro di raccolta del sangue:

O	A	O	AB	A	A	O	O	B	A
O	A	AB	B	O	O	O	A	B	A
A	O	A	A	O	B	A	O	AB	A
O	O	A	B	A	A	A	O	B	O
O	A	O	A	B	O	AB	A	O	B

In questo studio statistico abbiamo:

- Popolazione: donatori di sangue.

- Campione: i 50 donatori selezionati nel centro di raccolta.
- Variabile: gruppo sanguigno del sangue prelevato. Si tratta di una variabile qualitativa.

Possiamo raccogliere i dati in una tabella che renda più facile la lettura.

✘ Queste operazioni sono tipicamente svolte con semplici operazioni in fogli di calcolo utilizzando software adatti (es.: Microsoft Excel, WPS Office). Per contare i valori si possono utilizzare i comandi `CONTA`, `CONTA.VALORI`, `CONTA.NUMERI`, `CONTA.SE` *et similia*.

gruppo sanguigno	frequenze assolute	frequenze relative
A	19	38%
B	8	16%
AB	4	8%
O	19	38%
totale	50	100%

Rappresentiamo le frequenze assolute dei dati in un diagramma a barre.




FIGURA 1.6. Diagramma a barre delle frequenze assolute.

Rappresentiamo le frequenze relative in un diagramma a torta.




FIGURA 1.7. Diagramma a torta.

□

ESEMPIO 1.12. I voti degli studenti e studentesse di “Probabilità e Statistica” ad un appello sono stati i seguenti:³

23 29 22 26 30 20 23 20 26 26 24 24
 22 29 27 24 18 28 25 18 29 24 30 26
 28 30 27 23 28 16 22 19 25 30 24 25
 28 25 24 24 27 27 24 24 25 25 24 30
 19 25 17 26 25 22 24 30 22 30 21 30

In questo studio statistico:

- Popolazione: studenti e studentesse di “Probabilità e Statistica”.
- Campione: 60 iscritti ad un appello.
- Variabile: voto. È una variabile quantitativa discreta.

Raccogliamo i dati in una tabella delle frequenze

voti	freq. ass.	freq. rel.	voti	freq. ass.	freq. rel.
16	1	1.67%	24	11	18.33%
17	1	1.67%	25	8	13.33%
18	2	3.33%	26	5	8.33%
19	2	3.33%	27	4	6.67%
20	2	3.33%	28	4	6.67%
21	1	1.67%	29	3	5%
22	5	8.33%	30	8	13.34%
23	3	5%			

³I dati sono generati casualmente. Ogni riferimento a persone esistenti o a fatti realmente accaduti è puramente casuale.

⚠ Gli arrotondamenti possono causare uno scarto nella somma delle frequenze relative, che sappiamo dover essere sempre uguale al 100%. Qui l'ultima percentuale è stata corretta per fare in modo che la somma finale fosse 100%.

Rappresentiamo le frequenze relative in un diagramma a barre.




FIGURA 1.8. Diagramma a barre delle frequenze relative.

□




FIGURA 1.9. *xkcd* 688. SELF-DESCRIPTION. Credits: <https://xkcd.com/688/>

Se la variabile in esame è quantitativa continua, le frequenze definite come sopra non sono in grado di fornirci molte informazioni sul campione. Infatti il range dei valori che possono essere assunti è un intervallo di valori continui. La probabilità che un preciso valore venga assunto è zero.⁴

⁴Esprimeremo in modo rigoroso questa affermazione quando studieremo le variabili aleatorie continue con una densità.

ESEMPIO 1.13. Una casa farmaceutica produce un farmaco. Vengono elencati i dati del peso in milligrammi del farmaco:

5.582 5.603 5.622 5.651 5.671 5.673 5.681
 5.686 5.687 5.689 5.692 5.693 5.696 5.698
 5.703 5.704 5.705 5.715 5.717 5.719 5.728
 5.729 5.730 5.736 5.738 5.739 5.742 5.756
 5.759 5.762 5.765 5.772 5.778 5.784 5.807

x Utilizziamo in un foglio di calcolo il comando “Rimuovi duplicati”.

Ci rendiamo conto che tutti i valori sono unici, quindi ciascuno dei valori assunti ha frequenza assoluta 1. Questa descrizione non fornisce informazioni sulla distribuzione dei dati.




FIGURA 1.10. Per questo tipo di dati, le frequenze assolute non forniscono informazioni sulla distribuzione dei dati.

□

Per ovviare a questo problema e descrivere meglio i dati, i valori vengono raccolti in intervalli dette *classi*.

Consideriamo una variabile quantitativa continua e suddividiamo il range dei valori che può assumere in intervalli concatenati I_1, \dots, I_k della forma⁵

$$I_j = [a_j, b_j) = \{x \in \mathbb{R} \text{ tale che } a_j \leq x < b_j\},$$

dove $b_j = a_{j+1}$ per $j = 1, \dots, k - 1$. Le ampiezze degli intervalli $b_j - a_j$ non sono necessariamente tutte uguali tra loro. Si veda la Figure 1.11




FIGURA 1.11. Esempio di suddivisione del range di una variabile in classi.

⁵Si sceglie quale dei due estremi includere. La scelta è indifferente, l'importante è essere coerenti.

DEFINIZIONE 1.14. (Frequenze per dati raggruppati in classi.) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi che suddividono il range dei valori assunti. Le *frequenze assolute* delle classi I_1, \dots, I_k sono i numeri $f_1, \dots, f_k \in \{0, 1, \dots, n\}$ definiti da

$$f_j := \#\{i \in \{1, \dots, n\} \text{ tale che } x_i \in I_j\}.$$

Le *frequenze relative* sono i numeri $p_1, \dots, p_k \in [0, 1]$ definiti da

$$p_j := \frac{f_j}{n}.$$

□

OSSERVAZIONE 1.15. Le frequenze per dati raggruppati in classi hanno un difetto. Consideriamo dei dati distribuiti come segue:

classi	frequenze assolute
[1, 2)	3
[2, 6)	8
[6, 8)	4
[8, 9)	1

Rappresentiamo i dati in un diagramma a barre:




FIGURA 1.12. Diagramma a barre delle frequenze assolute.

Osserviamo che l'intervallo $[2, 6)$ è quello che contiene più dati. Tuttavia è anche l'intervallo più ampio! Quindi ci si poteva aspettare che contenesse più dati rispetto agli altri intervalli. Sarebbe più opportuno riportare la frequenza all'ampiezza dell'intervallo.

Approfittiamo per fare un'ulteriore osservazione sul diagramma a barre. A differenza di quanto detto per dati di variabili qualitative o quantitative discrete, non ha senso ridisegnare il diagramma riordinando gli intervalli, poiché questi sono concatenati. In effetti, per i dati raggruppati in classi viene utilizzato un diagramma differente, l'istogramma. □

DEFINIZIONE 1.16. (Densità di frequenze per dati raggruppati in classi.) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi che suddividono il range dei valori assunti. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute delle classi. Le *densità di frequenze assolute* delle classi I_1, \dots, I_k sono i numeri

$$\frac{f_j}{|I_j|}, \quad j = 1, \dots, k,$$

dove $|I_j| = b_j - a_j$ se $I_j = [a_j, b_j)$. Le *densità di frequenze relative* sono i numeri

$$\frac{p_j}{|I_j|}, \quad j = 1, \dots, k,$$

□

Le densità di frequenze vengono rappresentate in *istogrammi*. Si veda la Figura 1.13.




FIGURA 1.13. Istogramma delle densità di frequenze relative. Un istogramma delle densità di frequenze assolute è del tutto analogo: in quel caso le altezze dei rettangoli sono $\frac{f_j}{|I_j|}$.

OSSERVAZIONE 1.17. A differenza dei diagrammi a barre, negli istogrammi non ha senso riordinare gli intervalli poiché questi sono concatenati seguendo l'ordine dei valori nel range. Per evidenziare questa caratteristica dell'istogramma, le barre non vengono disegnate separate. □

OSSERVAZIONE 1.18. In un istogramma delle densità di frequenze assolute, ogni rettangolo ha base di lunghezza $|I_j| = b_j - a_j$ e altezza di lunghezza $\frac{f_j}{|I_j|}$. Segue che l'area di ogni rettangolo è f_j , ovvero la frequenza assoluta. In un istogramma delle densità di frequenze relative, ogni rettangolo ha base di lunghezza $|I_j| = b_j - a_j$ e altezza di lunghezza $\frac{p_j}{|I_j|}$. Segue che l'area di ogni rettangolo è p_j , ovvero la frequenza relativa. Per l'Osservazione 1.8 segue che l'area totale dell'istogramma è $1 = 100\%$.⁶ □

⁶Questo fatto è importantissimo ed è da ricordare per la parte di probabilità! In particolare per quando studieremo la densità delle variabili aleatorie continue.

ESEMPIO 1.19. Consideriamo i dati dell'Esempio 1.13. Raggruppiamo i dati nelle seguenti classi: $[5.500, 5.650)$, $[5.650, 5.700)$, $[5.700, 5.740)$, $[5.740, 5.770)$, $[5.770, 5.800)$, $[5.800, 5.900)$.

✎ Utilizziamo in un foglio di calcolo il comando `CONTA.SE` per contare il numero di valori in ciascun intervallo.

classi	freq. ass.	freq. rel.	densità di freq. ass.	densità di freq. rel.
$[5.500, 5.650)$	3	8.57%	20	0.57
$[5.650, 5.710)$	14	40%	233.33	6.67
$[5.710, 5.740)$	9	25.71%	300	8.57
$[5.740, 5.770)$	5	14.29%	166.67	4.76
$[5.770, 5.800)$	3	8.57%	100	2.86
$[5.800, 5.900)$	1	2.85%	10	0.29

Rappresentiamo i dati in un istogramma delle densità di frequenze relative.




FIGURA 1.14. Istogramma delle densità di frequenze relative.

□

1.3. Moda e classi modali

La moda rappresenta il valore più frequente nei dati. Per le variabili qualitative è il valore di sintesi più utilizzato (perché non è possibile fare operazioni aritmetiche sui valori assunti da una variabile qualitativa).

DEFINIZIONE 1.20. (Moda per variabili qualitative e quantitative discrete) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano v_1, \dots, v_k i valori distinti assunti dalla variabile in esame. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute e relative dei valori v_1, \dots, v_k . Un valore v_j è *modale* se

$$f_j \geq f_\ell \quad \text{per } \ell = 1, \dots, k,$$

o, equivalentemente,

$$p_j \geq p_\ell \quad \text{per } \ell = 1, \dots, k.$$

Un valore v_j si dice *moda* se è l'unico valore modale. □

ESEMPIO 1.21. Nell'Esempio 1.11 i gruppi sanguigni A e O sono i valori modali.

Nell'Esempio 1.12 il voto 24 è la moda. □

Per le variabili quantitative continue abbiamo visto che conviene raggruppare i valori in classi. Tuttavia, per individuare le classi modali è importante tenere conto dell'ampiezza degli intervalli.

DEFINIZIONE 1.22. (Classe modale per variabili quantitative continue) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi che suddividono il range dei valori assunti. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute delle classi. Una classe I_j si dice *modale* se

$$\frac{f_j}{|I_j|} \geq \frac{f_\ell}{|I_\ell|} \quad \text{per } \ell = 1, \dots, k,$$

o, equivalentemente

$$\frac{p_j}{|I_j|} \geq \frac{p_\ell}{|I_\ell|} \quad \text{per } \ell = 1, \dots, k,$$

Se esiste un'unica classe modale, viene detta *la classe modale*. □

ESEMPIO 1.23. Torniamo ai dati dell'Esempio 1.13 e studiamo l'istogramma delle densità di frequenze relative in Figura 1.14. C'è un'unica classe modale: [5.710, 5.740).

⚠ Questo esempio mostra il seguente fenomeno: può accadere che una classe abbia la frequenza (assoluta o relativa) maggiore, ma non sia la classe modale. Nell'esempio, la classe [5.650, 5.710) è quella con frequenza assoluta maggiore, ovvero è la classe che contiene più dati (14). Tuttavia è ben più ampia della classe [5.710, 5.740). Per individuare la classe modale occorre rapportare la frequenza all'ampiezza dell'intervallo. A parità di ampiezza, è la classe [5.710, 5.740) che contiene più dati. □

1.4. Media

La media calcolata su un campione di dati individua un valore centrale attorno a cui si distribuiscono i dati. Può essere utilizzata solo per variabili quantitative poiché richiede una formula con operazioni aritmetiche per essere calcolata.

DEFINIZIONE 1.24. (Media calcolata sui dati di un campione) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa discreta o continua). La *media calcolata sui dati del*

campione è il numero⁷

$$\bar{x}_n := \frac{1}{n} \sum_{i=1}^n x_i.$$

□

OSSERVAZIONE 1.25. La media calcolata su un campione può essere interpretata in questo modo: ad ogni dato viene associato un peso. Inoltre, il peso è lo stesso per tutti i dati, quindi ogni dato ha un peso $\frac{1}{n}$. I dati vengono posizionati sulla retta reale in base ai loro valori. La media \bar{x}_n è allora il baricentro (nel senso fisico) dei dati pesati con questo peso. □

Utilizzando l'osservazione precedente si fornisce la definizione di media pesata.

DEFINIZIONE 1.26. (Media pesata calcolata sui dati di un campione) Siano $\lambda_1, \dots, \lambda_n \in [0, 1]$ pesi tale che $\sum_{i=1}^n \lambda_i = 1$. Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa discreta o continua). La *media pesata calcolata sui dati del campione* è il numero

$$\sum_{i=1}^n \lambda_i x_i.$$

□

ESEMPIO 1.27. Consideriamo i dati nell'Esempio 1.12.

✎ In un foglio di calcolo si usa il comando `MEDIA` per calcolare la media sui dati di un campione.

La media risulta essere: 24.8. □

OSSERVAZIONE 1.28. Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano v_1, \dots, v_k i valori distinti assunti dalla variabile in esame. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute e relative dei valori v_1, \dots, v_k . Possiamo riorganizzare i termini nella formula della media calcolata sui dati del campione per ottenere le seguenti formule equivalenti:

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{j=1}^k f_j v_j = \sum_{j=1}^k p_j v_j. \quad (1.1)$$

□

ESEMPIO 1.29. Consideriamo i dati nell'Esempio 1.12. Allora la media si può calcolare come segue:

$$\bar{x} = 16 \cdot 1.67\% + 17 \cdot 1.67\% + 18 \cdot 3.33\% + \dots + 28 \cdot 6.67\% + 29 \cdot 5\% + 30 \cdot 13.34\%.$$

□

⁷Ometteremo la n e scriveremo \bar{x} se non è importante sottolineare l'ampiezza del campione.

Utilizziamo l'osservazione precedente per approssimare la media quando i dati sono raggruppati in classi e non sono noti precisamente i valori dei dati. Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi che suddividono il range dei valori assunti. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute delle classi. Per ogni classe $I_j = [a_j, b_j)$ definiamo il valore centrale

$$\tilde{v}_j = \frac{a_j + b_j}{2}.$$

Approssimiamo la formula (1.1) sostituendo ai valori assunti i valori centrali delle classi, ovvero

$$\bar{x}_n \simeq \sum_{j=1}^k p_j \tilde{v}_j. \quad (1.2)$$

ESEMPIO 1.30. Si studia il tempo di vita di una batteria per smartphone. I dati misurati (in anni) vengono raccolti in intervalli e si contano le osservazioni negli intervalli:

intervalli (anni)	frequenza assoluta
[0, 3)	3
[3, 4)	4
[4, 5)	6
[5, 7)	10
[7, 12)	7

Approssimiamo la media dei dati. Completiamo la tabella con le informazioni utili ad approssimare la media:

intervalli (anni)	valori centrali	frequenza assoluta	frequenza relativa
[0, 3)	1.5	3	10%
[3, 4)	3.5	4	13.33%
[4, 5)	4.5	6	20%
[5, 7)	6	10	33.33%
[7, 12)	9.5	7	23.34%

Un'approssimazione della media è

$$\bar{x} \simeq 1.5 \cdot 10\% + 3.5 \cdot 13.33\% + 4.5 \cdot 20\% + 6 \cdot 33.33\% + 9.5 \cdot 23.34\% \simeq 5.73.$$

□

OSSERVAZIONE 1.31. Consideriamo dei dati x_1, \dots, x_n . Supponiamo di avere altri dati y_1, \dots, y_n ottenuti dai dati x_1, \dots, x_n tramite una trasformazione affine, ovvero

$$y_i = ax_i + b, \quad \text{per } i = 1, \dots, n.$$

(Attenzione: a e b sono gli stessi per tutte le i .) Allora

$$\bar{y}_n = a\bar{x}_n + b.$$

Infatti

$$\bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{n} \sum_{i=1}^n (ax_i + b) = a \frac{1}{n} \sum_{i=1}^n x_i + b = a\bar{x}_n + b.$$

In conclusione, la media di dati trasformati tramite una trasformazione affine è ottenuta applicando la trasformazione affine alla media. ⁸ \square

ESEMPIO 1.32. Consideriamo i dati x_1, \dots, x_n ottenuti dalla misurazione della temperatura corporea in gradi Fahrenheit. La media dei dati è $\bar{x} = 97.772^\circ F$. Possiamo calcolare la media dei dati in gradi Celsius senza dover convertire tutti i dati x_i in gradi Celsius. Ricordiamo che c'è una trasformazione affine che trasforma i gradi Fahrenheit in Celsius e viceversa. Se x_i sono i dati in gradi Fahrenheit e y_i sono i dati in gradi Celsius, abbiamo che

$$y_i = ax_i + b.$$

Ricordiamo che:

- l'acqua congela a $32^\circ F$;
- l'acqua bolle a $212^\circ F$.

Possiamo determinare a e b :

$$\begin{cases} 0 = 32a + b \\ 100 = 212a + b \end{cases} \implies \begin{cases} 100 = 180a \\ 0 = 32a + b \end{cases} \implies \begin{cases} a = \frac{5}{9} \\ b = -32\frac{5}{9} \end{cases}$$

quindi

$$y_i = \frac{5}{9}(x_i - 32).$$

Allora

$$\bar{y} = \frac{5}{9}(\bar{x} - 32) = \frac{5}{9}(97.772 - 32) = 36.54.$$

\square

1.5. Varianza e deviazione standard

Definiamo una quantità utile a misurare la dispersione dei dati rispetto alla media.

DEFINIZIONE 1.33. (Varianza e deviazione standard calcolate sui dati di un campione) Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa). Sia \bar{x}_n la media calcolata sui dati del campione. La *varianza calcolata sui dati del campione* è data da⁹

$$s_n^2 := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2.$$

La *deviazione standard calcolata sui dati del campione* s_n è data dalla radice della varianza. \square

⁸Nonostante questa osservazione possa sembrare banale, è una proprietà che non vale per tutti i valori di sintesi. Vedremo, ad esempio, che non è vera per la deviazione standard nell'Osservazione 1.37.

⁹Ometteremo la n e scriveremo s^2 oppure s_x^2 se vogliamo sottolineare di quali dati stiamo calcolando la varianza.

OSSERVAZIONE 1.34. La varianza calcolata sui dati del campione ha come unità di misura l'unità di misura al quadrato dei dati. La deviazione standard ha la stessa unità di misura dei dati. \square

La varianza calcolata sui dati del campione misura, in media e quadraticamente, quanto i dati si discostano dalla media. Il motivo per cui si divide per $(n - 1)$ anziché n sarà chiaro quando studieremo la parte di statistica inferenziale alla fine del corso. Per ora possiamo aggrapparci alla seguente idea: siccome stiamo utilizzando la media calcolata sui dati nel campione nella formula, che si ottiene dai dati stessi, è come se avessimo un dato in meno.

OSSERVAZIONE 1.35. Possiamo utilizzare una formula alternativa per la varianza, pratica per lo svolgimento degli esercizi:

$$\begin{aligned} s_n^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x}_n + \bar{x}_n^2) \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - 2\bar{x}_n \sum_{i=1}^n x_i + n\bar{x}_n^2 \right) = \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - 2n\bar{x}_n^2 + n\bar{x}_n^2 \right) \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n\bar{x}_n^2 \right). \end{aligned}$$

\square

ESEMPIO 1.36. Consideriamo i dati nell'Esempio 1.12.

x In un foglio di calcolo si usa il comando `VAR` o `VAR.C` per calcolare la varianza sui dati di un campione. Il comando `VAR.P` non utilizza la definizione fornita sopra, ma divide la somma per n . Per calcolare la deviazione standard si usa il comando `DEV.ST` o `DEV.ST.C`.

La varianza risulta essere 12.74. La deviazione standard risulta essere 3.57. \square

OSSERVAZIONE 1.37. Consideriamo dei dati x_1, \dots, x_n . Supponiamo di avere altri dati y_1, \dots, y_n ottenuti dai dati x_1, \dots, x_n tramite una trasformazione affine, ovvero

$$y_i = ax_i + b, \quad \text{per } i = 1, \dots, n.$$

(Attenzione: a e b sono gli stessi per tutte le i .) Siano s_x e s_y la deviazione standard dei dati x_1, \dots, x_n e dei dati y_1, \dots, y_n , rispettivamente. Allora

$$s_y^2 = a^2 s_x^2.$$

Infatti, per l'Osservazione 1.31 e per la definizione di varianza

$$\begin{aligned} s_y^2 &= \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n (ax_i + b - a\bar{x} - b)^2 \\ &= a^2 \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = a^2 s_x^2. \end{aligned}$$

Segue che

$$s_y = |a|s_x.$$

□

ESEMPIO 1.38. Consideriamo i dati x_1, \dots, x_n ottenuti dalla misurazione della temperatura corporea in gradi Fahrenheit. La deviazione standard dei dati è $s_x = 1.8^\circ F$. Possiamo calcolare la deviazione standard dei dati in gradi Celsius senza dover convertire tutti i dati x_i in gradi Celsius. Ricordiamo che c'è una trasformazione affine che trasforma i gradi Fahrenheit in Celsius e viceversa, ottenuta nell'Esempio 1.32:

$$y_i = \frac{5}{9}(x_i - 32).$$

Quindi

$$s_y = \frac{5}{9} \cdot s_x = \frac{5}{9} \cdot 1.8 = 1^\circ C.$$

□

ESERCIZIO 1.39. Una persona nell'ultimo mese è andata in viaggio a Londra per 10 volte. La media dei costi dei biglietti aereo è €120, con una deviazione standard calcolata sui dati pari a €7. Il cambio euro/sterlina al momento delle prenotazioni era €1 = £0.87. Per ogni prenotazione c'è una commissione pari a £1. Calcolare la media e la deviazione standard dei dati espresse in sterline. □

ESERCIZIO 1.40. La media e la varianza calcolate sui dati di una campione di ampiezza 5 sono, rispettivamente, 104 e 4. Tre dei valori sono 102, 100, 105. Quali sono gli altri due valori? □

OSSERVAZIONE 1.41. Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano v_1, \dots, v_k i valori distinti assunti dalla variabile in esame. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute e relative dei valori v_1, \dots, v_k . Possiamo riorganizzare i termini nella formula della varianza calcolata sui dati del campione per ottenere le seguenti formule equivalenti:

$$\begin{aligned} s_n^2 &= \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n\bar{x}_n^2 \right) = \frac{1}{n-1} \left(\sum_{j=1}^k f_j v_j^2 - n\bar{x}_n^2 \right) \\ &= \frac{n}{n-1} \left(\sum_{j=1}^k p_j v_j^2 - \bar{x}_n^2 \right). \end{aligned} \tag{1.3}$$

□

Utilizziamo l'osservazione precedente per approssimare la varianza e la deviazione standard quando i dati sono raggruppati in classi e non sono noti precisamente i valori dei dati. Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi

che suddividono il range dei valori assunti. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute delle classi. Per ogni classe $I_j = [a_j, b_j)$ definiamo il valore centrale

$$\tilde{v}_j = \frac{a_j + b_j}{2}.$$

Approssimiamo la formula (1.3) sostituendo ai valori assunti i valori centrali delle classi, ovvero

$$s_n^2 \simeq \frac{n}{n-1} \left(\sum_{j=1}^k p_j v_j^2 - \bar{x}_n^2 \right), \quad (1.4)$$

dove il valore \bar{x}_n può essere sostituito con l'approssimazione (1.2). Se il numero dei dati non è noto e si sa che il campione è numeroso, si può approssimare $\frac{n}{n-1}$ con 1.¹⁰ La deviazione standard è quindi approssimata da

$$s_n \simeq \sqrt{\frac{n}{n-1} \left(\sum_{j=1}^k p_j v_j^2 - \bar{x}_n^2 \right)}.$$

ESEMPIO 1.42. Torniamo all'Esempio 1.30, dove abbiamo ottenuto l'approssimazione della media $\bar{x} \simeq 5.73$. Utilizziamo la formula (1.4) per approssimare la varianza calcolata sui dati del campione:

$$\begin{aligned} s^2 &\simeq \frac{30}{29} \left(10\% \cdot 1.5^2 + 13.33\% \cdot 3.5^2 + 20\% \cdot 4.5^2 + 33.33\% \cdot 6 + 23.34\% \cdot 9.5^2 - 5.73^2 \right) \\ &\simeq 6.35. \end{aligned}$$

La deviazione standard approssimata è $\sqrt{6.35} \simeq 2.52$. □

1.6. Quartili, percentili, quantili

I valori di sintesi che consideriamo in questa sezione descrivono come i dati vengono suddivisi all'interno del campione.

1.6.1. Quartili. Iniziamo definendo i quartili. Consideriamo i dati di un campione x_1, \dots, x_n . Per prima cosa ordiniamo i dati. A meno di permutare gli indici, possiamo supporre che

$$x_1 \leq x_2 \leq \dots \leq x_n.$$

I quartili sono tre valori Q_1, Q_2, Q_3 che suddividono i dati x_1, \dots, x_n in quattro parti.

Per fornire precisamente la definizione, occorre fissare un criterio con cui suddividere i dati. Si distinguono due criteri: quello per calcolare i quartili esclusivi e quello per calcolare i quartili inclusivi.

L'idea per definire i quartili esclusivi è quella di posizionare i dati su un segmento di lunghezza $(n+1)$ come in Figura 1.15. I dati non vengono posizionati sugli estremi del segmento e per questo i quartili si dicono esclusivi. Si divide il segmento in 4 parti uguali. I punti ottenuti individuano la posizione dei quartili, che vengono calcolati di conseguenza.

¹⁰Si consiglia di tenere a mente questa formula per quando studieremo la varianza delle variabili aleatorie nella parte di probabilità.




FIGURA 1.15. Esempio di suddivisione di dati ordinati con tre quartili esclusivi.

DEFINIZIONE 1.43. (Quartili esclusivi) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione. Per definire il *primo quartile* esclusivo Q_1 si scrive $(n+1)\frac{1}{4} = k_1 + r_1$ con $k_1 \in \mathbb{N}$ e $r_1 \in \{0, \frac{1}{4}, \frac{1}{2}, \frac{3}{4}\}$. Si definisce

$$Q_1 := (1 - r_1)x_{k_1} + r_1x_{k_1+1}.$$

Per definire il *secondo quartile* o *mediana* Q_2 si scrive $(n+1)\frac{2}{4} = k_2 + r_2$ con $k_2 \in \mathbb{N}$ e $r_2 \in \{0, \frac{1}{2}\}$. Si definisce

$$Q_2 := (1 - r_2)x_{k_2} + r_2x_{k_2+1}.$$

Per definire il *terzo quartile* esclusivo Q_3 si scrive $(n+1)\frac{3}{4} = k_3 + r_3$ con $k_3 \in \mathbb{N}$ e $r_3 \in \{0, \frac{1}{4}, \frac{1}{2}, \frac{3}{4}\}$. Si definisce

$$Q_3 := (1 - r_3)x_{k_3} + r_3x_{k_3+1}.$$

□

L'idea per definire i quartili inclusivi è quella di posizionare i dati su un segmento di lunghezza $(n-1)$ come in Figura 1.16. I dati vengono posizionati sugli estremi del segmento e per questo i quartili si dicono inclusivi. Si divide il segmento in 4 parti uguali. I punti ottenuti individuano la posizione dei quartili, che vengono calcolati di conseguenza.




FIGURA 1.16. Esempio di suddivisione di dati ordinati con tre quartili inclusivi.

DEFINIZIONE 1.44. (Quartili inclusivi) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione. Per definire il *primo quartile* inclusivo Q_1 si scrive $(n-1)\frac{1}{4} = k_1 + r_1$ con $k_1 \in \mathbb{N}$ e $r_1 \in \{0, \frac{1}{4}, \frac{1}{2}, \frac{3}{4}\}$. Si definisce

$$Q_1 := (1 - r_1)x_{k_1+1} + r_1x_{k_1+2}.$$

Per definire il *secondo quartile* o *mediana* Q_2 si scrive $(n-1)\frac{2}{4} = k_2 + r_2$ con $k_2 \in \mathbb{N}$ e $r_2 \in \{0, \frac{1}{2}\}$. Si definisce

$$Q_2 := (1 - r_2)x_{k_2+1} + r_2x_{k_2+2}.$$

Per definire il *terzo quartile* inclusivo Q_3 si scrive $(n - 1)\frac{3}{4} = k_3 + r_3$ con $k_3 \in \mathbb{N}$ e $r_3 \in \{0, \frac{1}{4}, \frac{1}{2}, \frac{3}{4}\}$. Si definisce

$$Q_3 := (1 - r_3)x_{k_3+1} + r_3x_{k_3+2}.$$

□

ESEMPIO 1.45. Si misura il carico di rottura a trazione di alcuni provini di acciaio INOX. Le misurazioni in $MPa = N/mm^2$ sono le seguenti:

792 706 737 580 692 720 711 704 749 725 734 702

Calcoliamo i quartili dei dati. Per prima cosa ordiniamo i dati:

580 692 702 704 706 711 720 725 734 737 749 792

Abbiamo $n = 12$ dati.

Calcoliamo il primo quartile esclusivo: $(n + 1)\frac{1}{4} = \frac{13}{4} = 3 + 0.25$. Allora

$$Q_1 = (1 - 0.25)x_3 + 0.25x_4 = 0.75 \cdot 702 + 0.25 \cdot 704 = 702.5.$$

Calcoliamo il secondo quartile: $(n + 1)\frac{2}{4} = 13\frac{2}{4} = 6 + 0.5$. Allora

$$Q_2 = (1 - 0.5)x_6 + 0.5x_7 = 0.5 \cdot 711 + 0.5 \cdot 720 = 715.5.$$

Calcoliamo il terzo quartile esclusivo: $(n + 1)\frac{3}{4} = 13\frac{3}{4} = 9 + 0.75$. Allora

$$Q_3 = (1 - 0.75)x_9 + 0.75x_{10} = 0.25 \cdot 734 + 0.75 \cdot 737 = 736.25.$$

x In un foglio di calcolo si determinano i quartili esclusivi con il comando `ESC.QUARTILE`.

Calcoliamo il primo quartile inclusivo: $(n - 1)\frac{1}{4} = \frac{11}{4} = 2 + 0.75$. Allora

$$Q_1 = (1 - 0.75)x_3 + 0.75x_4 = 0.25 \cdot 702 + 0.75 \cdot 704 = 703.5.$$

Calcoliamo il terzo quartile esclusivo: $(n - 1)\frac{3}{4} = 11\frac{3}{4} = 8 + 0.25$. Allora

$$Q_3 = (1 - 0.25)x_9 + 0.25x_{10} = 0.75 \cdot 734 + 0.25 \cdot 737 = 734.75.$$

x In un foglio di calcolo si determinano i quartili inclusivi con il comando `INC.QUARTILE` o equivalentemente con il comando `QUARTILE`. □

OSSERVAZIONE 1.46. A differenza della media calcolata sui dati del campione, la mediana è meno sensibile alla presenza di dati anomali. Per mostrare questo fenomeno, consideriamo, a titolo di esempio, i seguenti dati:

1 1 3 5 6 8 10 12

La media calcolata su questi dati è

$$\frac{1}{8}(1 + 1 + 3 + 5 + 6 + 8 + 10 + 12) = 5.75.$$

La mediana è

$$Q_2 = 5.5.$$

Supponiamo che i dati siano leggermente differenti, ovvero:

$$1 \quad 1 \quad 3 \quad 5 \quad 6 \quad 8 \quad 10 \quad 40.$$

Osserviamo che solo l'ultimo dato è diverso dai dati precedenti ed è molto grande. La media risulta essere

$$\frac{1}{8}(1 + 1 + 3 + 5 + 6 + 8 + 10 + 40) = 9.25.$$

Osserviamo che la media è cambiata, poiché la formula che definisce la media utilizza tutti i dati, ciascuno pesato allo stesso modo.

La mediana, invece è la stessa, poiché è definita solo utilizzando la posizione dei dati. Quindi $Q_2 = 5.5$.

□

1.6.2. Percentili. I percentili sono analoghi ai quartili. Sono 99 e dividono i dati in 100 parti.

DEFINIZIONE 1.47. (Percentili) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione. Sia $h \in \{1, \dots, 99\}$. Per definire l'*h-esimo percentile esclusivo* P_h si scrive $(n+1)\frac{h}{100} = k+r$ con $k \in \mathbb{N}$ e $r \in \{0, \frac{1}{100}, \dots, \frac{99}{100}\}$. Si definisce

$$P_h := (1-r)x_k + rx_{k+1}.$$

Per definire l'*h-esimo percentile inclusivo* P_h si scrive $(n-1)\frac{h}{100} = k+r$ con $k \in \mathbb{N}$ e $r \in \{0, \frac{1}{100}, \dots, \frac{99}{100}\}$. Si definisce

$$P_h := (1-r)x_{k+1} + rx_{k+2}.$$

□

x In un foglio di calcolo, i percentili esclusivi si ottengono con `ESC.PERCENTILE`. Si determinano i percentili inclusivi con il comando `INC.PERCENTILE` o equivalentemente con il comando `PERCENTILE`.

OSSERVAZIONE 1.48. I quartili Q_1 , Q_2 , Q_3 sono rispettivamente il 25°, il 50° e il 75° percentile. □

ESEMPIO 1.49. Calcoliamo il 90° percentile per i dati nell'Esempio 1.45. Si ha che $(n+1) \cdot \frac{90}{100} = 13\frac{9}{10} = 11.7 = 11 + 0.7$. Segue che

$$P_{90} = (1-0.7) \cdot 749 + 0.7 \cdot 792 = 779.1.$$

□

1.6.3. Quantili. I quantili sono la generalizzazione dei percentili e possono individuare una porzione di dati fornito un qualunque $\alpha \in (0, 1)$.

DEFINIZIONE 1.50. (Quantili) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione. Sia $\alpha \in (0, 1)$. Per definire il *quantile* di ordine α esclusivo q_α si scrive $(n+1)\alpha = k+r$ con $k \in \mathbb{N}$ e $r \in [0, 1)$. Si definisce

$$q_\alpha := (1-r)x_k + rx_{k+1}.$$

Per definire *il quantile* di ordine α inclusivo q_α si scrive $(n-1)\alpha = k+r$ con $k \in \mathbb{N}$ e $r \in [0,1)$. Si definisce

$$q_\alpha := (1-r)x_{k+1} + rx_{k+2}.$$

□

OSSERVAZIONE 1.51. L' h -esimo percentile è il quantile di ordine $\frac{h}{100}$.

□

1.6.4. Approssimazione dei quantili per dati raggruppati in classi. Supponiamo di avere dei dati raggruppati in classi senza conoscere i valori precisi dei dati. Vogliamo approssimare il quantile q_α di ordine $\alpha \in (0,1)$.

Consideriamo un campione di ampiezza n estratto da una popolazione. Siano x_1, \dots, x_n i dati raccolti per la variabile in esame (quantitativa continua). Siano I_1, \dots, I_k le classi che suddividono il range dei valori assunti. Siano f_1, \dots, f_k e p_1, \dots, p_k rispettivamente le frequenze assolute delle classi.

Definiamo le *frequenze assolute cumulate*

$$F_j := \sum_{\ell=1}^j f_\ell.$$

La frequenza assoluta cumulata F_j è il numero di dati contenuti nell'unione degli intervalli $I_1 \cup \dots \cup I_j$.

Cerchiamo l'intervallo in cui la frequenza assoluta cumulata raggiunge una porzione α dei dati, ovvero l'intervallo $I_j = [a_j, b_j)$ tale che

$$F_{j-1} \leq \alpha n < F_j.$$

Allora possiamo approssimare il quantile di ordine α con il punto nell'intervallo $[a_j, b_j)$ dato da

$$q_\alpha \simeq a_j + \lambda_j(b_j - a_j),$$

dove

$$\lambda_j = \frac{\alpha n - F_{j-1}}{F_j - F_{j-1}} \in [0,1). \quad (1.5)$$

OSSERVAZIONE 1.52. Il peso λ_j definito in (1.5) è definito in modo che il quantile sia sbilanciato verso uno dei due estremi in base alla quantità di dati contenuti fino all'intervallo I_j . Se, ad esempio, $n\alpha = F_{j-1}$, vuol dire che $n\alpha$ dati sono stati raggiunti fino al valore a_j . Se invece $n\alpha = F_j$, vuol dire che $n\alpha$ valori sono raggiunti all'estremo b_j . La formula (1.5) tiene presente tutti i casi intermedi. □

ESEMPIO 1.53. Consideriamo i dati nell'Esempio 1.30. Aggiungiamo le frequenze assolute cumulate alla tabella:

intervalli (anni)	frequenza assoluta	frequenza cumulata
[0, 3)	3	3
[3, 4)	4	7
[4, 5)	6	13
[5, 7)	10	23
[7, 12)	7	30

Calcoliamo, ad esempio, il terzo quartile (ovvero il 75° percentile, ovvero il quantile di ordine 0.75). La porzione di dati $30 \cdot \frac{3}{4} = 22.5$. Nell'intervallo $[5, 7)$ viene raggiunta questo numero di dati, quindi Q_3 sarà posizionato in $[5, 7)$. Lo approssimiamo con

$$Q_3 \simeq 5 + \lambda(7 - 5),$$

dove λ è dato da

$$\lambda = \frac{22.5 - 13}{23 - 13} = 0.95.$$

Quindi

$$Q_3 \simeq 5 + 0.95 \cdot 2 = 6.9.$$

Come ci potevamo aspettare, Q_3 è molto più vicino a 7 che a 5 poiché l'intervallo contiene 23 dati (molto vicino a 22.5). \square

1.6.5. Dati anomali e sospetti. Vista l'Osservazione 1.46, possiamo usare i quartili per individuare valori centrali dei dati e dati che si discostano troppo da questi da identificare come anomali o sospetti.

DEFINIZIONE 1.54. (IQR) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione con quartili Q_1, Q_2, Q_3 . Il *range interquartile* è il numero

$$IQR := Q_3 - Q_1.$$

\square

Le seguenti definizioni sono fornite su base empirica.

DEFINIZIONE 1.55. (Dati anomali e sospetti) Siano $x_1 \leq \dots \leq x_n$ i dati ordinati di un campione con range interquartile IQR . Un dato x_i si dice *anomalo* se

$$x_i \in (-\infty, Q_1 - 3 \cdot IQR] \cup [Q_3 + 3 \cdot IQR, +\infty).$$

Un dato x_i si dice *sospetto* se

$$x_i \in (Q_1 - 3 \cdot IQR, Q_1 - 1.5 \cdot IQR] \cup [Q_3 + 1.5 \cdot IQR, Q_3 + 1.5 \cdot IQR).$$

\square

ESEMPIO 1.56. Consideriamo i dati dell'Esempio 1.45. Il range interquartile è (usando i quartili esclusivi)

$$IQR = Q_3 - Q_1 = 736.25 - 702.5 = 33.75.$$

Per individuare i dati anomali calcoliamo gli intervalli:

$$(-\infty, Q_1 - 3 \cdot IQR] \cup [Q_3 + 3 \cdot IQR, +\infty) = (-\infty, 601.25] \cup [837.5, +\infty).$$

Poiché 580 è minore di 601.25, si ha che 580 è un dato anomalo.

Per individuare i dati sospetti, calcoliamo gli intervalli:

$$\begin{aligned} & (Q_1 - 3 \cdot IQR, Q_1 - 1.5 \cdot IQR] \cup [Q_3 + 1.5 \cdot IQR, Q_3 + 1.5 \cdot IQR) \\ &= (601.25, 651.875] \cup [786.875, 837.5). \end{aligned}$$

Poiché 792 appartiene al secondo intervallo, è un dato sospetto. \square

1.6.6. Box-plot. Il *box-plot* o *diagramma a scatola e baffi* è un diagramma che descrive la distribuzione dei dati utilizzando i quartili. La struttura del box-plot è riassunta in Figura 1.17.




FIGURA 1.17. Attenzione: disegno non in scala! Struttura di un box-plot. La scatola è delimitata dal primo e dal terzo quartile. Viene evidenziata la mediana. I baffi si estendono dalla scatola fino al più piccolo e al più grande valore né anomali né sospetti.

ESEMPIO 1.57. Disegniamo il box-plot per i dati nell'Esempio 1.45.




FIGURA 1.18. Box-plot per i dati nell'Esempio 1.45.

□




FIGURA 1.19. *xkcd* 539. BOYFRIEND. Credits: <https://xkcd.com/539/>

1.7. Regressione lineare

Vogliamo individuare uno strumento capace di misurare il modo di variare di una variabile quantitativa rispetto a un'altra.¹¹ Consideriamo due set di dati che corrispondono ai valori osservati nella misurazione di due variabili per un campione estratto da una popolazione. Possiamo elencare i dati come coppie

$$(x_1, y_1), \dots, (x_n, y_n)$$

e rappresentarli in una tabella:

valori della variabile x	valori della variabile y
x_1	y_1
x_2	y_2
\vdots	\vdots
x_n	y_n

Scatterplot. I dati di due variabili possono essere rappresentati in uno *scatterplot* o *diagramma a dispersione*. Si veda la Figura 1.20 per la struttura di uno scatterplot.




FIGURA 1.20. In uno scatterplot si rappresentano i dati $(x_1, y_1), \dots, (x_n, y_n)$ tramite n punti con coordinate con ascissa x_i e ordinata y_i .

In questa parte del corso ci occuperemo del problema di individuare una correlazione tra i dati x_i e i dati y_i . Nella fattispecie, capiremo come quantificare una correlazione lineare. Si veda la Figura 1.21 per un'idea qualitativa del concetto di correlazione tra dati di due variabili.

¹¹Comprenderemo nella parte di probabilità il significato rigoroso di “influenza”.




FIGURA 1.21. A sinistra: esempio di uno scatterplot per dati con una correlazione lineare. Al centro: esempio di uno scatterplot per dati con una correlazione non lineare. A destra: esempio di uno scatterplot per dati scorrelati.

La correlazione lineare si manifesta in un aspetto dello scatterplot con l'andamento simile a quello di una retta. Il nostro obiettivo è ora individuare la retta di equazione

$$y = ax + b$$

che meglio approssima i dati.

Se per ogni $i = 1, \dots, n$ avessimo

$$y_i = ax_i + b, \tag{1.6}$$

la correlazione lineare tra i dati sarebbe perfetta poiché i punti dello scatterplot giacerebbero sulla retta di equazione $y = ax + b$.

Se la relazione (1.6) non è verificata, possiamo considerare i residui

$$y_i - (ax_i + b).$$

Una quantità che globalmente tiene conto di tutti i residui è (il simbolo e viene dall'inglese *sum of squared errors*)

$$e(a, b) := \sum_{i=1}^n \left(y_i - (ax_i + b) \right)^2.$$

La minimizzazione dell'errore $e(a, b)$ è detta *metodo dei minimi quadrati*.

Queste considerazioni ci portano a formulare la seguente definizione.

DEFINIZIONE 1.58. Siano $(x_1, y_1), \dots, (x_n, y_n)$ i dati di due variabili di un campione. La *retta di regressione lineare* è la retta di equazione

$$y = \hat{a}x + \hat{b},$$

dove $\hat{a}, \hat{b} \in \mathbb{R}$ sono i coefficienti che minimizzano $e(a, b)$, ovvero

$$e(\hat{a}, \hat{b}) \leq e(a, b), \quad \text{per ogni } a, b \in \mathbb{R}.$$

□

Mostriamo come determinare i coefficienti \hat{a} e \hat{b} . Vogliamo minimizzare l'errore

$$e(a, b) = \sum_{i=1}^n (y_i - ax_i - b)^2.$$

I punti di minimo sono punti critici. Cerchiamo allora \hat{a}, \hat{b} tra i punti a, b per cui $\nabla e(a, b) = (0, 0)$. Imponiamo questa condizione, ovvero,

$$0 = \partial_a e(a, b) = -2 \sum_{i=1}^n (y_i - ax_i - b)x_i = -2 \sum_{i=1}^n (x_i y_i - ax_i^2 - bx_i),$$

$$0 = \partial_b e(a, b) = -2 \sum_{i=1}^n (y_i - ax_i - b)$$

Dalla seconda equazione segue che

$$nb = \sum_{i=1}^n (y_i - ax_i) \implies b = \bar{y} - a\bar{x}.$$

Sostituendo nella prima,

$$\begin{aligned} \sum_{i=1}^n (x_i y_i - ax_i^2 - bx_i) = 0 &\implies \sum_{i=1}^n (x_i y_i - ax_i^2 - x_i \bar{y} + a\bar{x}x_i) = 0 \\ &\implies a \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \\ &\implies a = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}. \end{aligned}$$

In conclusione

$$\hat{a} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad (1.7)$$

$$\hat{b} = \bar{y} - \hat{a}\bar{x} \quad (1.8)$$

costituiscono l'unico punto (\hat{a}, \hat{b}) per cui il gradiente si annulla. D'altro canto, la funzione $e(a, b)$ è convessa. Infatti, calcoliamo le derivate seconde

$$\partial_{aa}^2 e(a, b) = 2 \sum_{i=1}^n x_i^2, ,$$

$$\partial_{ab}^2 e(a, b) = 2 \sum_{i=1}^n x_i = 2n\bar{x},$$

$$\partial_{bb}^2 e(a, b) = 2 \sum_{i=1}^n 1 = 2n.$$

Deduciamo che la matrice Hessiana è data da

$$\nabla^2 e(a, b) = \begin{pmatrix} 2 \sum_{i=1}^n x_i^2 & 2n\bar{x} \\ 2n\bar{x} & 2n \end{pmatrix}.$$

Questa matrice è semidefinita positiva, poiché la traccia è

$$2 \sum_{i=1}^n x_i^2 + 2n \geq 0$$

e il determinante è

$$4n \sum_{i=1}^n x_i^2 - 4n^2 \bar{x}^2 = 4n(n-1)s_x^2 \geq 0,$$

dove abbiamo usato l'Osservazione 1.35.¹² Quindi $e(a, b)$ è convessa in ogni punto e il suo punto critico (\hat{a}, \hat{b}) è un punto di minimo.

DEFINIZIONE 1.59. Siano $(x_1, y_1), \dots, (x_n, y_n)$ i dati di due variabili di un campione. La *covarianza calcolata sui dati del campione* è la quantità

$$\text{cov}_{x,y} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

□

OSSERVAZIONE 1.60. Dalla definizione otteniamo direttamente che

$$\text{cov}_{x,x} = s_x^2,$$

ovvero la covarianza dei dati x_i rispetto agli stessi x_i è pari alla varianza dei dati. □

OSSERVAZIONE 1.61. C'è un modo alternativo per calcolare la covarianza sui dati di un campione analoga a quella ottenuta nell'Osservazione 1.35 per la varianza. Infatti, sviluppando il prodotto

$$\begin{aligned} \text{cov}_{x,y} &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n-1} \sum_{i=1}^n (x_i y_i - \bar{y} x_i - \bar{x} y_i + \bar{x} \bar{y}) \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n x_i y_i - \bar{y} \sum_{i=1}^n x_i - \bar{x} \sum_{i=1}^n y_i + n \bar{x} \bar{y} \right) \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n x_i y_i - 2n \bar{x} \bar{y} + n \bar{x} \bar{y} \right) = \frac{1}{n-1} \left(\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} \right). \end{aligned}$$

□

OSSERVAZIONE 1.62. Sia $y = \hat{a}x + \hat{b}$ la retta di regressione lineare dei dati. Osserviamo che

$$\hat{a} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{\frac{1}{n-1} \sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\frac{1}{n-1} \sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{\text{cov}_{x,y}}{s_x^2}.$$

Possiamo interpretare questa formula nel seguente modo: la pendenza della retta di regressione lineare \hat{a} è ottenuta calcolando quanto variano i dati y_i rispetto ai dati x_i e rapportando questa quantità a quanto variano i dati x_i . □

¹²La matrice $\nabla^2 e(a, b)$ è simmetrica, quindi ha due autovalori reali λ_1, λ_2 . Ricordiamo che la traccia è $\lambda_1 + \lambda_2$ e il determinante è $\lambda_1 \lambda_2$. Poiché queste quantità sono maggiori o uguali a zero, concludiamo che $\lambda_1, \lambda_2 \geq 0$, ovvero la matrice è semidefinita positiva.

DEFINIZIONE 1.63. Siano $(x_1, y_1), \dots, (x_n, y_n)$ i dati di due variabili di un campione. Il coefficiente di correlazione lineare o indice di correlazione di Pearson è il numero

$$\rho_{x,y} := \frac{\text{COV}_{x,y}}{s_x s_y} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sqrt{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \sqrt{\sum_{i=1}^n y_i^2 - n\bar{y}^2}}.$$

□




FIGURA 1.22. A sinistra: Auguste Bravais (1811-1863).^a Al centro: Francis Galton (1822-1911).^b A destra: Karl Pearson (1857-1936).^c Il coefficiente di correlazione lineare è stato introdotto da Bravais e successivamente studiato da Galton e Pearson. Prende il nome da quest'ultimo.

^aFonte dell'immagine: <https://commons.wikimedia.org/wiki/File:Bravais2.gif>.

^bFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Sir_Francis_Galton_by_Gustav_Graef.jpg.

^cFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Karl_Pearson,_1912.jpg.

OSSERVAZIONE 1.64. In alternativa, il coefficiente di correlazione lineare si può calcolare tramite la formula

$$\rho_{x,y} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sqrt{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \sqrt{\sum_{i=1}^n y_i^2 - n\bar{y}^2}} = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \frac{\sqrt{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}{\sqrt{\sum_{i=1}^n y_i^2 - n\bar{y}^2}} = \hat{a} \frac{s_x}{s_y}.$$

□

PROPOSIZIONE 1.65. Siano $(x_1, y_1), \dots, (x_n, y_n)$ i dati di due variabili di un campione. Sia $\rho_{x,y}$ il coefficiente di correlazione lineare. Si ha che $-1 \leq \rho_{x,y} \leq 1$. Inoltre, se $|\rho_{x,y}| = 1$, allora i dati sono posizionati su una retta, ovvero $y_i = \hat{a}x_i + \hat{b}$ per ogni $i = 1, \dots, n$.

DIMOSTRAZIONE. Consideriamo i vettori

$$v = \begin{pmatrix} x_1 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{pmatrix}, \quad w = \begin{pmatrix} y_1 - \bar{y} \\ \vdots \\ y_n - \bar{y} \end{pmatrix}.$$

Calcoliamo la lunghezza di questi vettori

$$|v|^2 = \sum_{i=1}^n (x_i - \bar{x})^2, \quad |w|^2 = \sum_{i=1}^n (y_i - \bar{y})^2.$$

Osserviamo che

$$\begin{aligned} 0 &\leq \left| \frac{v}{|v|} - \frac{w}{|w|} \right|^2 = \left(\frac{v}{|v|} - \frac{w}{|w|} \right) \cdot \left(\frac{v}{|v|} - \frac{w}{|w|} \right) = \frac{v \cdot v}{|v|^2} - 2 \frac{v \cdot w}{|v||w|} + \frac{w \cdot w}{|w|^2} \\ &= 1 - 2 \frac{v \cdot w}{|v||w|} + 1 \implies \frac{v \cdot w}{|v||w|} \leq 1 \implies v \cdot w \leq |v||w|, \end{aligned} \quad (1.9)$$

ovvero

$$\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \leq 1, \quad (1.10)$$

da cui $\rho_{x,y} \leq 1$. Per l'altra disuguaglianza, osserviamo che

$$\begin{aligned} 0 &\leq \left| \frac{v}{|v|} + \frac{w}{|w|} \right|^2 = \left(\frac{v}{|v|} + \frac{w}{|w|} \right) \cdot \left(\frac{v}{|v|} + \frac{w}{|w|} \right) = \frac{v \cdot v}{|v|^2} + 2 \frac{v \cdot w}{|v||w|} - \frac{w \cdot w}{|w|^2} \\ &= 1 + 2 \frac{v \cdot w}{|v||w|} + 1 \implies \frac{v \cdot w}{|v||w|} \leq 1, \end{aligned}$$

ovvero

$$\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \geq -1,$$

da cui $\rho_{x,y} \geq -1$.

Supponiamo che $\rho_{x,y} = 1$ e mostriamo che i dati sono perfettamente correlati linearmente. Ispezionando (1.10) e (1.9) e procedendo a ritroso nei conti, otteniamo che

$$\frac{v \cdot w}{|v||w|} = 1 \implies 1 - 2 \frac{v \cdot w}{|v||w|} + 1 = 0 \implies \left| \frac{v}{|v|} - \frac{w}{|w|} \right|^2 = 0$$

da cui segue che

$$\frac{v}{|v|} = \frac{w}{|w|} \implies w = \frac{|w|}{|v|} v \implies \begin{pmatrix} y_1 - \bar{y} \\ \vdots \\ y_n - \bar{y} \end{pmatrix} = \frac{|w|}{|v|} \begin{pmatrix} x_1 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{pmatrix}$$

ovvero

$$y_i = \frac{|w|}{|v|} x_i + \bar{y} - \frac{|w|}{|v|} \bar{x} = \hat{a} x_i + \hat{b} \quad \text{per } i = 1, \dots, n.$$

Se invece $\rho_{x,y} = -1$, un ragionamento analogo permette di concludere che

$$y_i = -\frac{|w|}{|v|} x_i + \bar{y} - \frac{|w|}{|v|} \bar{x} = \hat{a} x_i + \hat{b} \quad \text{per } i = 1, \dots, n.$$

□

La precedente proposizione mostra che il coefficiente di correlazione lineare è un numero puro compreso tra -1 e 1 . In base al coefficiente di correlazione lineare, si può comprendere quanto sono correlati i dati. Se $\rho_{x,y}$ è molto vicino a 1 , i dati hanno una forte correlazione positiva (la retta di regressione lineare è crescente). Se $\rho_{x,y}$ è molto vicino a -1 , i dati hanno una forte correlazione negativa (la retta di regressione lineare è decrescente). Se $\rho_{x,y}$ è vicino a 0 , non c'è correlazione lineare.

Se ci interessa solamente l'intensità della correlazione e non il segno della correlazione, possiamo utilizzare un altro strumento, detto *coefficiente di determinazione* o semplicemente *coefficiente R^2* . Viene calcolato così: individuamo la retta di regressione lineare di equazione

$$y = \hat{a}x + \hat{b}.$$

La retta è stata ottenuta minimizzando l'errore $e(a, b)$. Chiamiamo SSE l'errore corrispondente alla retta di regressione lineare, ovvero

$$\text{SSE} = e(\hat{a}, \hat{b}) = \sum_{i=1}^n (y_i - \hat{a}x_i - \hat{b})^2.$$

Il numero SSE fornisce l'errore che si commette nel prevedere i dati y utilizzando il modello $\hat{a}x + \hat{b}$. Vogliamo confrontare questo errore con l'errore che si commetterebbe nel prevedere i dati y utilizzando semplicemente la loro media, ovvero utilizzando la retta di equazione $y = \bar{y}$. Per definizione, la retta di regressione lineare minimizza l'errore, quindi

$$\text{SSE} = e(\hat{a}, \hat{b}) \leq e(0, \bar{y}) = \sum_{i=1}^n (y_i - \bar{y})^2 = (n-1)s_y^2 =: \text{SS}_y.$$

Possiamo osservare che la quantità a destra è proporzionale alla varianza dei dati y_1, \dots, y_n . Calcoliamo il rapporto

$$\frac{\text{SSE}}{\text{SS}_y} \leq 1 \implies 1 - \frac{\text{SSE}}{\text{SS}_y} \geq 0.$$

DEFINIZIONE 1.66. Il *coefficiente di determinazione* o *coefficiente R^2* è il numero

$$R^2 := 1 - \frac{\text{SSE}}{\text{SS}_y}.$$


□

Un coefficiente R^2 pari a 0 equivale a dire che l'errore commesso nel prevedere i dati y utilizzando il modello $\hat{a}x + \hat{b}$ è uguale a quello che si commette nell'usare semplicemente la media \bar{y} . Questo vuol dire che i dati x non sono utili a migliorare le previsioni dei dati y . Un coefficiente R^2 pari a 1 equivale a dire che l'errore commesso nel prevedere i dati y utilizzando il modello $\hat{a}x + \hat{b}$ è uguale a 0, ovvero c'è correlazione lineare perfetta nei dati.

OSSERVAZIONE 1.67. C'è un legame tra il coefficiente R^2 e il coefficiente di correlazione lineare. Utilizzando (1.7) e (1.8), osserviamo che

$$\begin{aligned}
 R^2 &= 1 - \frac{\text{SSE}}{\text{SS}_y} = \frac{\text{SS}_y - \text{SSE}}{\text{SS}_y} = \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (y_i - \hat{a}x_i - \hat{b})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &= \frac{\sum_{i=1}^n (y_i - \bar{y} + y_i - \hat{a}x_i - \hat{b})(y_i - \bar{y} - y_i + \hat{a}x_i + \hat{b})}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &= \frac{\sum_{i=1}^n (y_i - \bar{y} + y_i - \hat{a}x_i - \bar{y} + \hat{a}\bar{x})(y_i - \bar{y} - y_i + \hat{a}x_i + \bar{y} - \hat{a}\bar{x})}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &= \frac{\sum_{i=1}^n (2(y_i - \bar{y}) - \hat{a}(x_i - \bar{x}))(\hat{a}(x_i - \bar{x}))}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &= 2\hat{a} \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2} - \hat{a}^2 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \\
 &= 2\hat{a}^2 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} - \hat{a}^2 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \hat{a}^2 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \hat{a}^2 \frac{s_x^2}{s_y^2} = \rho_{x,y}^2,
 \end{aligned}$$

dove abbiamo utilizzato l'Osservazione 1.64. □



I DON'T TRUST LINEAR REGRESSIONS WHEN IT'S HARDER
TO GUESS THE DIRECTION OF THE CORRELATION FROM THE
SCATTER PLOT THAN TO FIND NEW CONSTELLATIONS ON IT.

FIGURA 1.23. *xkcd* 1725. LINEAR REGRESSION. Credits: <https://xkcd.com/1725/>

⚠ Non bisogna confondere il concetto di correlazione con quello di causa ed effetto. Un esempio per convincere di questa differenza è il seguente. Si considerino il numero di pirati (dati x_i) in relazione alla temperatura media mondiale (dati y_i). Osserviamo in Figura 1.24 che c'è una forte correlazione tra i dati. Questo non vuol dire che aumentando il numero di pirati si risolverebbe il problema del riscaldamento globale!




FIGURA 1.24. Immagine tratta da Wikimedia Commons. The original uploader was LiamVleck at English Wikibooks., CC BY-SA 3.0 <<https://creativecommons.org/licenses/by-sa/3.0/>>, via Wikimedia Commons.




FIGURA 1.25. *xkcd* 552. CORRELATION. Credits: <https://xkcd.com/552/>

ESEMPIO 1.68. Ci si aspetta che la resa percentuale di una reazione chimica sia correlata con la temperatura a cui avviene la reazione. Nella seguente tabella sono rappresentati i dati di un campione:

temperatura ($^{\circ}C$)	45	55	60	70	85	90
resa (%)	43	48	51	57	66	68

Rappresentiamo i dati in uno scatterplot (nella figura è rappresentata anche la retta di regressione lineare).




FIGURA 1.26. Scatterplot e retta di regressione lineare.

Denotiamo con $(x_1, y_1), \dots, (x_n, y_n)$, $n = 6$, i dati del campione. Cerchiamo la retta di equazione

$$y = ax + b$$

che meglio approssima i dati, utilizzando il metodo dei minimi quadrati. Vogliamo minimizzare l'errore

$$e(a, b) = \sum_{i=1}^n (y_i - ax_i - b)^2.$$

Imponiamo che il gradiente rispetto ad (a, b) sia nullo, ovvero,

$$0 = \partial_a e(a, b) = -2 \sum_{i=1}^n (y_i - ax_i - b)x_i = -2 \sum_{i=1}^n (x_i y_i - ax_i^2 - bx_i),$$

$$0 = \partial_b e(a, b) = -2 \sum_{i=1}^n (y_i - ax_i - b)$$

Dalla seconda equazione segue che

$$nb = \sum_{i=1}^n (y_i - ax_i) \implies b = \bar{y} - a\bar{x}.$$

Sostituendo nella prima,

$$\begin{aligned} \sum_{i=1}^n (x_i y_i - ax_i^2 - bx_i) = 0 &\implies \sum_{i=1}^n (x_i y_i - ax_i^2 - x_i \bar{y} + a\bar{x} x_i) = 0 \\ &\implies a \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = \sum_{i=1}^n x_i y_i - n\bar{x} \bar{y} \\ &\implies a = \frac{\sum_{i=1}^n x_i y_i - n\bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}. \end{aligned}$$

Completiamo la tabella con i valori necessari a calcolare a e b :

							somma
x_i	45	55	60	70	85	90	405
y_i	43	48	51	57	66	68	333
x_i^2	2025	3025	3600	4900	7225	8100	28875
y_i^2	1849	2304	2601	3249	4356	4624	18983
$x_i y_i$	1935	2640	3060	3990	5610	6120	23355

Pertanto $\bar{x} = 405/6 = 67.5$ e $\bar{y} = 55.5$. Segue che

$$\hat{a} = \frac{23355 - 6 \cdot 67.5 \cdot 55.5}{28875 - 6 \cdot 67.5^2} = \frac{877.5}{1537.5} \simeq 0.57,$$

$$\hat{b} = 55.5 - 0.57 \cdot 67.5 \simeq 17.03,$$

ovvero, la retta di regressione lineare ha equazione

$$y = 0.57x + 17.03.$$

Per calcolare il coefficiente di correlazione lineare usiamo la formula

$$\begin{aligned} \rho_{x,y} &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \sqrt{\sum_{i=1}^n y_i^2 - n \bar{y}^2}} = \frac{23355 - 6 \cdot 67.5 \cdot 55.5}{\sqrt{28875 - 6 \cdot 67.5^2} \sqrt{18983 - 6 \cdot 55.5^2}} \\ &= \frac{877.5}{\sqrt{1537.5} \sqrt{501.5}} \simeq 0.9993. \end{aligned}$$

Il coefficiente R^2 è

$$R^2 = \rho_{x,y}^2 = 0.99860049.$$

□

x In un foglio di calcolo si può usare il comando REGR.LIN per calcolare i coefficienti della retta di regressione lineare.




FIGURA 1.27. *xkcd* 2048. CURVE-FITTING. Credits: <https://xkcd.com/2048/>

CAPITOLO 2

Probabilità

Contenuti

2.1. Spazi di probabilità, primi esempi e prime proprietà	41
Spazio degli eventi elementari	42
σ -algebra degli eventi	43
Misura di probabilità	45
2.1.1. Esercizi	54
2.2. Enumerazione	56
Principio fondamentale del calcolo combinatorio	56
Disposizioni	56
Permutazioni	58
Combinazioni semplici	59
2.2.1. Esercizi	61
2.3. Probabilità condizionata ed eventi indipendenti	63
Probabilità condizionata	63
2.3.1. Esercizi	72
Eventi indipendenti	74
2.3.2. Esercizi	78

2.1. Spazi di probabilità, primi esempi e prime proprietà




FIGURA 2.1. *xkcd* 628. PSYCHIC. Credits: <https://xkcd.com/628/>

Abbiamo imparato a osservare e descrivere i dati di un campione. Da ora in poi ci occuperemo del problema di quantificare le previsioni per fenomeni non descrivibili con un approccio deterministico. La teoria della probabilità è costituita da un insieme di strumenti pensati per questo scopo.

Innanzitutto dobbiamo capire come formulare una teoria capace di descrivere in modo rigoroso dei fenomeni non deterministici.

Spazio degli eventi elementari. Per descrivere un esperimento probabilistico formuleremo un modello. Il primo ingrediente del modello è lo *spazio degli eventi elementari* o *spazio campione*, ovvero un insieme non vuoto $\Omega \neq \emptyset$. Gli elementi $\omega \in \Omega$ sono detti *eventi elementari*¹ e devono essere interpretati come le possibili osservazioni dell'esperimento probabilistico.

ESEMPIO 2.1. (Lancio di una moneta) Supponiamo di lanciare una moneta. I due possibili esiti del lancio sono testa T e croce C . Questi sono gli eventi elementari. Lo spazio degli eventi elementari è

$$\Omega = \{T, C\}.$$

□

ESEMPIO 2.2. (Lancio di un dado) Supponiamo di lanciare un dado. I possibili esiti del lancio sono i numeri da 1 a 6. Lo spazio degli eventi elementari è

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$

□

ESEMPIO 2.3. (Lancio di due monete) Supponiamo di lanciare due monete. I possibili esiti di questo esperimento sono le possibili coppie di esiti di lancio di una moneta, quindi lo spazio degli eventi elementari è dato da

$$\Omega = \{(T, T), (T, C), (C, T), (C, C)\}.$$

□

ESEMPIO 2.4. (Lancio di una moneta in sequenza) Supponiamo di lanciare una moneta infinite volte in sequenza. I possibili esiti sono sequenze della forma $\omega = (a_1, a_2, \dots, a_n, \dots)$ con $a_i \in \{T, C\}$. Quindi lo spazio degli eventi elementari è

$$\Omega = \{\omega = (a_1, a_2, \dots, a_n, \dots) \text{ con } a_i \in \{T, C\} \text{ per ogni } i \in \mathbb{N}\}.$$

Osserviamo che Ω è un insieme infinito (non numerabile).

□

ESEMPIO 2.5. (Tiro a bersaglio) Supponiamo di lanciare una freccetta su un bersaglio circolare. I possibili esiti del lancio sono i punti del cerchio. Lo spazio degli eventi elementari può essere modellato come un disco nel piano di raggio $r > 0$:

$$\Omega = \{\omega \in \mathbb{R}^2 \text{ tale che } |\omega| \leq r\}.$$

□

¹▲ Attenzione, gli *eventi elementari* sono un oggetti diversi dagli *eventi* che descriveremo dopo.

σ -algebra degli eventi. L'obiettivo della probabilità è quello di studiare eventi. Gli eventi sono il secondo ingrediente di un modello probabilistico. Un evento è una collezione di eventi elementari, ovvero un sottoinsieme di $A \subset \Omega$. Ad ogni spazio di eventi elementari Ω viene associata una famiglia di eventi \mathcal{F} . È importante che la famiglia soddisfi alcune proprietà. Bisogna ricordare che: l'intero spazio è un evento; il complementare di un evento è un evento; l'unione di eventi è un evento. Più rigorosamente, si richiede che la famiglia di eventi \mathcal{F} sia una σ -algebra.

DEFINIZIONE 2.6. Sia $\Omega \neq \emptyset$. Sia \mathcal{F} una famiglia di sottoinsiemi di Ω . Si dice che \mathcal{F} è una σ -algebra se verifica le seguenti proprietà:

- (1) $\Omega \in \mathcal{F}$.
- (2) Se $A \in \mathcal{F}$, allora $\Omega \setminus A \in \mathcal{F}$.
- (3) Se $(A_i)_{i \in \mathbb{N}} \subset \mathcal{F}$, allora $\bigcup_{i \in \mathbb{N}} A_i \in \mathcal{F}$.

□

OSSERVAZIONE 2.7. Dalle proprietà nella Definizione 2.6 si deducono altre proprietà importanti.

L'insieme vuoto è un evento. Infatti $\Omega \in \mathcal{F}$ per la (1) e quindi $\emptyset = \Omega \setminus \Omega \in \mathcal{F}$ per la (2). L'insieme \emptyset è detto *evento nullo*.

L'unione finita di eventi è un evento. Se $A, B \in \mathcal{F}$, allora $A \cup B \in \mathcal{F}$. Infatti, è sufficiente considerare la successione di insiemi i cui primi due elementi sono A e B e tutti gli altri elementi sono \emptyset e applicare la proprietà (3). Chiaramente, la condizione (3) è più forte perché chiede che la proprietà valga per una collezione numerabile di insiemi.²

L'intersezione di una collezione numerabile di eventi è un evento. Infatti, sia $(A_i)_{i \in \mathbb{N}} \subset \mathcal{F}$. Allora, per la (2), per ogni $i \in \mathbb{N}$ si ha che $\Omega \setminus A_i \in \mathcal{F}$. Per la (3) si ha che

$$\bigcup_{i \in \mathbb{N}} \Omega \setminus A_i \in \mathcal{F}.$$

Il complementare dell'unione è l'intersezione, quindi

$$\Omega \setminus \bigcup_{i \in \mathbb{N}} A_i = \bigcap_{i \in \mathbb{N}} \Omega \setminus A_i \in \mathcal{F}.$$

Utilizzando nuovamente la (2) concludiamo che

$$\bigcap_{i \in \mathbb{N}} A_i = \Omega \setminus \left(\Omega \setminus \bigcap_{i \in \mathbb{N}} A_i \right) \in \mathcal{F}.$$

In particolare, anche l'intersezione finita di eventi è un evento, ovvero se $A, B \in \mathcal{F}$, allora $A \cap B \in \mathcal{F}$. □

ESEMPIO 2.8. (Lancio di un dado) Consideriamo il lancio di un dado. Lo spazio degli eventi elementari è

$$\Omega = \{1, 2, 3, 4, 5, 6\}.$$

²Se la (3) fosse sostituita con la proprietà che l'unione finita di eventi è un evento, si avrebbe un'algebra di insiemi. La lettera " σ " viene aggiunta alla nomenclatura per sottolineare che la proprietà vale per collezioni numerabili.

Consideriamo come collezione di eventi \mathcal{F} tutti i possibili sottoinsiemi di Ω . In questo esempio li elenchiamo tutti per aiutare a comprendere il significato di “evento”:

$$\begin{aligned} \mathcal{F} = \{ & \emptyset, \\ & \{1\}, \{2\}, \{3\}, \{4\}, \{5\}, \{6\}, \\ & \{1, 2\}, \{1, 3\}, \{1, 4\}, \{1, 5\}, \{1, 6\}, \{2, 3\}, \{2, 4\}, \{2, 5\}, \{2, 6\}, \{3, 4\}, \{3, 5\}, \{3, 6\}, \\ & \{4, 5\}, \{4, 6\}, \{5, 6\}, \\ & \{1, 2, 3\}, \{1, 2, 4\}, \{1, 2, 5\}, \{1, 2, 6\}, \{1, 3, 4\}, \{1, 3, 5\}, \{1, 3, 6\}, \{1, 4, 5\}, \{1, 4, 6\}, \\ & \{1, 5, 6\}, \{2, 3, 4\}, \{2, 3, 5\}, \{2, 3, 6\}, \{2, 4, 5\}, \{2, 4, 6\}, \{2, 5, 6\}, \{3, 4, 5\}, \{3, 4, 6\}, \\ & \{3, 5, 6\}, \{4, 5, 6\}, \\ & \{3, 4, 5, 6\}, \{2, 4, 5, 6\}, \{2, 3, 5, 6\}, \{2, 3, 4, 6\}, \{2, 3, 4, 5\}, \{1, 4, 5, 6\}, \{1, 3, 5, 6\}, \\ & \{1, 3, 4, 6\}, \{1, 3, 4, 5\}, \{1, 2, 5, 6\}, \{1, 2, 4, 6\}, \{1, 2, 4, 5\}, \{1, 2, 3, 6\}, \{1, 2, 3, 5\}, \\ & \{1, 2, 3, 4\}, \\ & \{2, 3, 4, 5, 6\}, \{1, 3, 4, 5, 6\}, \{1, 2, 4, 5, 6\}, \{1, 2, 3, 5, 6\}, \{1, 2, 3, 4, 6\}, \{1, 2, 3, 4, 5\}, \\ & \{1, 2, 3, 4, 5, 6\} \}. \end{aligned}$$

In tutti ci sono 64 eventi. Questo esempio, di per sé semplice, mostra come possa essere complicato elencare tutti i possibili eventi. Per questo motivo diventerà fondamentale imparare a contare. Contando, potremo fare considerazioni sulle probabilità senza dover elencare tutti i possibili eventi.

La difficoltà maggiore degli esercizi di probabilità è interpretare eventi spiegati a parole in termini di insiemi. Alcuni esempi, in questo caso sono:

$$\text{“L’esito è pari”} = \{2, 4, 6\},$$

$$\text{“L’esito è un numero minore o uguale a 3”} = \{1, 2, 3\},$$

$$\text{“L’esito è un numero pari minore o uguale a 3”} = \{2, 4, 6\} \cap \{1, 2, 3\} = \{2\},$$

$$\text{“L’esito è un numero pari o minore o uguale a 3”} = \{2, 4, 6\} \cup \{1, 2, 3\} = \{1, 2, 3, 4, 6\},$$

$$\text{“L’esito non è un numero pari”} = \Omega \setminus \{2, 4, 6\} = \{1, 3, 5\}.$$

□

OSSERVAZIONE 2.9. In generale, se lo spazio degli eventi elementari $\Omega \neq \emptyset$ è un insieme finito, si sceglie come collezione di eventi la collezione di tutti i possibili sottoinsiemi di Ω . □

ESERCIZIO 2.10. Mostrare che se $\#\Omega = n$ e \mathcal{F} è la collezione di tutti i sottoinsiemi di Ω , allora $\#\mathcal{F} = 2^n$. □

Misura di probabilità. Con la teoria della probabilità, ad ogni evento associamo un peso. Il terzo ingrediente di un modello probabilistico è la misura di probabilità.

DEFINIZIONE 2.11. Sia $\Omega \neq \emptyset$ e sia \mathcal{F} una σ -algebra di sottoinsiemi di Ω . Una *misura di probabilità* è una funzione $\mathbb{P}: \mathcal{F} \rightarrow [0, 1]$ tale che:

(1) $\mathbb{P}(\Omega) = 1$.

(2) (*σ -additività per eventi mutuamente disgiunti*) Se $(A_i)_{i \in \mathbb{N}} \subset \mathcal{F}$ soddisfano $A_i \cap A_j = \emptyset$ per $i \neq j$, allora

$$\mathbb{P}\left(\bigcup_{i \in \mathbb{N}} A_i\right) = \sum_{i \in \mathbb{N}} \mathbb{P}(A_i).$$

□

OSSERVAZIONE 2.12. Tipicamente $\mathbb{P}(A) \in [0, 1]$ viene espressa in percentuale. □

DEFINIZIONE 2.13. Uno *spazio di probabilità* è una terna $(\Omega, \mathcal{F}, \mathbb{P})$ dove $\Omega \neq \emptyset$ è lo spazio degli eventi elementari, \mathcal{F} è una σ -algebra di sottoinsiemi di Ω , \mathbb{P} è una misura di probabilità. □



FIGURA 2.3. Andrej Nikolajewitsch Kolmogorov (1903–1987). A lui è dovuta la definizione assiomatica della probabilità.^a

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Andrej_Nikolajewitsch_Kolmogorov.jpg

OSSERVAZIONE 2.14. Se lo spazio degli eventi elementari $\Omega \neq \emptyset$ è finito, è sufficiente conoscere la misura di probabilità sugli eventi elementari per conoscerla su tutti gli eventi. Infatti, supponiamo che

$$\Omega = \{\omega_1, \dots, \omega_n\}.$$

Siano

$$p_i := \mathbb{P}(\{\omega_i\}), \quad \text{per } i = 1, \dots, n.$$

si pone

$$\mathbb{P}(A) := \sum_{j=1}^k p_{i_j}.$$

□

ESEMPIO 2.15. (Lancio di una moneta) Lo spazio di probabilità che descrive il lancio di una moneta è costituito dallo spazio di eventi elementari

$$\Omega = \{T, C\},$$

la collezione di eventi \mathcal{F} costituita da tutti i sottoinsiemi di Ω e la misura di probabilità definita da

$$\mathbb{P}(\{T\}) = \mathbb{P}(\{C\}) = \frac{1}{2}.$$

□

ESEMPIO 2.16. (Lancio di una moneta truccata) Lo spazio di probabilità che descrive il lancio di una moneta truccata è costituito dallo spazio di eventi elementari

$$\Omega = \{T, C\},$$

la collezione di eventi \mathcal{F} costituita da tutti i sottoinsiemi di Ω e la misura di probabilità definita da

$$\mathbb{P}(\{T\}) = p, \quad \mathbb{P}(\{C\}) = 1 - p,$$

dove $p \in [0, 1]$. La moneta è truccata se $p \neq \frac{1}{2}$.

□




FIGURA 2.4. *xkcd* 2370. PREDICTION. Credits: <https://xkcd.com/2370/>

OSSERVAZIONE 2.17. (Probabilità dell'evento nullo) Dimostriamo che $\mathbb{P}(\emptyset) = 0$. Infatti \emptyset e \emptyset sono disgiunti, banalmente perché $\emptyset \cap \emptyset = \emptyset$. Allora, per l'additività, $\mathbb{P}(\emptyset) = \mathbb{P}(\emptyset \cup \emptyset) = \mathbb{P}(\emptyset) + \mathbb{P}(\emptyset) = 2\mathbb{P}(\emptyset)$, da cui $\mathbb{P}(\emptyset) = 0$. □

OSSERVAZIONE 2.18. (Probabilità della differenza di insiemi) Siano A, B due eventi tali che $A \subset B$. Allora B e $A \setminus B$ sono disgiunti e $A = (A \setminus B) \cup B$. Per l'additività, segue che

$$\mathbb{P}(A) = \mathbb{P}((A \setminus B) \cup B) = \mathbb{P}(A \setminus B) + \mathbb{P}(B) \implies \mathbb{P}(A \setminus B) = \mathbb{P}(A) - \mathbb{P}(B).$$

□

OSSERVAZIONE 2.19. (Probabilità del complementare) Se A è un evento, allora $\mathbb{P}(\Omega \setminus A) = 1 - \mathbb{P}(A)$. Questo segue direttamente dall'Osservazione 2.18. □

ESEMPIO 2.20. (Lancio di un dado) Lo spazio di probabilità che descrive il lancio di un dado è costituito dallo spazio degli eventi elementari

$$\Omega = \{1, 2, 3, 4, 5, 6\},$$

la collezione di eventi \mathcal{F} costituita da tutti i sottoinsiemi di Ω e la misura di probabilità definita da

$$\mathbb{P}(\{1\}) = \mathbb{P}(\{2\}) = \mathbb{P}(\{3\}) = \mathbb{P}(\{4\}) = \mathbb{P}(\{5\}) = \mathbb{P}(\{6\}) = \frac{1}{6}.$$

Possiamo calcolare la probabilità di alcuni eventi. Ad esempio, calcoliamo la probabilità che l'esito del lancio sia pari, ovvero che si verifichi l'evento

$$A = \{2, 4, 6\}$$

Utilizzando l'additività della misura di probabilità

$$\mathbb{P}(A) = \mathbb{P}(\{2, 4, 6\}) = \mathbb{P}(\{2\}) + \mathbb{P}(\{4\}) + \mathbb{P}(\{6\}) = \frac{1}{6} + \frac{1}{6} + \frac{1}{6} = \frac{1}{2}.$$

Possiamo calcolare direttamente la probabilità che l'esito sia un numero dispari. Infatti questa è la probabilità dell'evento complementare

$$\mathbb{P}(\Omega \setminus A) = 1 - \mathbb{P}(A) = 1 - \frac{1}{2} = \frac{1}{2}.$$

□

OSSERVAZIONE 2.21. (Eventi favorevoli diviso eventi possibili) **⚠** Spesso associamo la formula “eventi favorevoli diviso eventi possibili” alla probabilità per spazi di probabilità finiti. Questa formula è vera in alcuni casi, ma è falsa in altri casi. Spieghiamo qui in che senso.

Partiamo con un esempio. Consideriamo un dado truccato nel seguente modo:

$$\Omega = \{1, 2, 3, 4, 5, 6\},$$

$$\mathbb{P}(\{1\}) = \frac{1}{2}, \quad \mathbb{P}(\{2\}) = \mathbb{P}(\{3\}) = \mathbb{P}(\{4\}) = \mathbb{P}(\{5\}) = \mathbb{P}(\{6\}) = \frac{1}{10}.$$

Calcoliamo la probabilità che l'esito del lancio sia un numero minore o uguale a 3, ovvero dell'evento

$$A = \{1, 2, 3\}.$$

Se usassimo la formula “eventi favorevoli diviso eventi possibili” avremmo $\frac{3}{6} = \frac{1}{2}$. Tuttavia abbiamo che, per l’additività,

$$\mathbb{P}(A) = \mathbb{P}(\{1\}) + \mathbb{P}(\{2\}) + \mathbb{P}(\{3\}) = \frac{1}{2} + \frac{1}{10} + \frac{1}{10} = \frac{5 + 1 + 1}{10} = \frac{7}{10} \neq \frac{1}{2}.$$

Il motivo è che nel caso del dado truccato le probabilità non sono uniformi.

▲ La formula “eventi favorevoli diviso eventi possibili” è valida quando le probabilità sono distribuite *uniformemente*, ovvero quando le probabilità degli eventi elementari sono tutte uguali.

Per dimostrare l’affermazione precedente, consideriamo uno spazio di probabilità finito

$$\Omega = \{\omega_1, \dots, \omega_n\},$$

con misura di probabilità uniforme

$$\mathbb{P}(\{\omega_i\}) = \frac{1}{n}.$$

Consideriamo un evento costituito da k elementi

$$A = \{\omega_{i_1}, \dots, \omega_{i_k}\}.$$

Per l’additività si ha che

$$\mathbb{P}(A) = \sum_{j=1}^k \mathbb{P}(\{\omega_{i_j}\}) = \sum_{j=1}^k \frac{1}{n} = \frac{k}{n} = \frac{\#A}{\#\Omega}.$$

□

OSSERVAZIONE 2.22. ♣ Se si ha a che fare con spazi di eventi elementari discreti infiniti o continui, la scelta della collezione di eventi può essere delicata e, in generale, non si può sempre scegliere la collezione di tutti i sottoinsiemi di Ω . Gli insiemi della collezione \mathcal{F} devono godere, in un certo senso, di “buone proprietà”.

In questi casi delicati, la pratica è la seguente: si definisce \mathbb{P} su eventi “semplici” e si individua una σ -algebra \mathcal{F} che contenga gli eventi “semplici” e per cui \mathbb{P} può essere estesa a \mathcal{F} .

Se $\Omega = \mathbb{R}^n$, tipicamente viene usata come collezione di eventi \mathcal{F} la σ -algebra dei cosiddetti insiemi Boreliani. Per questo corso non ci interessa conoscere la struttura degli insiemi Boreliani, ma ci interessa sapere che:

- gli insiemi aperti sono Boreliani;
- gli insiemi chiusi sono Boreliani;
- le unioni e le intersezioni numerabili di aperti e chiusi sono Boreliani;
- degli insiemi Boreliani si può calcolare la misura n -dimensionale.

Chi vuole approfondire l’argomento può consultare [1, Capitolo 5].

□




FIGURA 2.5. Émile Borel (1871–1956).^a Diede importanti contributi alla teoria della misura, utilizzata per rendere rigorosa la definizione di spazio di probabilità. Gli insiemi Boreliani prendono il nome da lui.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Emile_Borel-1932.jpg.

ESEMPIO 2.23. (Tiro a bersaglio) Consideriamo lo spazio degli eventi elementari

$$\Omega = \{\omega \in \mathbb{R}^2 \text{ tale che } |\omega| \leq r\}.$$

Si considera la collezione di eventi \mathcal{F} costituita dai sottoinsiemi Boreliani di \mathbb{R}^2 contenuti in Ω . Per ogni $A \in \mathcal{F}$ si può calcolare l'area $|A|$. Si definisce la misura di probabilità

$$\mathbb{P}(A) := \frac{1}{\pi r^2} |A|.$$

Il fattore $\frac{1}{\pi r^2}$ è necessario affinché $\mathbb{P}(\Omega) = \frac{1}{\pi r^2} |\Omega| = \frac{1}{\pi r^2} \pi r^2 = 1$. □

ESEMPIO 2.24. (Paradosso di Bertrand) Il seguente esempio mostra come sia delicata la scelta del modello nel momento in cui si vuole descrivere un esperimento probabilistico nel continuo. L'esempio introduce anche al concetto di distribuzione di probabilità che verrà approfondito durante il resto del corso.

Domanda. Consideriamo un cerchio di raggio 1 e un triangolo equilatero inscritto nel cerchio. Qual è la probabilità che una corda scelta a caso sia più lunga del lato del triangolo inscritto?



FIGURA 2.6. Joseph Bertrand (1822–1900).^a Nel lavoro *Calcolo delle probabilità* del 1889 propone il problema spiegato in questo esempio.

^aFonte dell'immagine: <https://commons.wikimedia.org/wiki/File:Bertrand.jpg>

Proposta di soluzione 1. Per descrivere la corda scelta a caso nel cerchio è sufficiente generare due punti a caso sulla circonferenza. Poiché ci interessa solo la lunghezza della corda, possiamo ruotare la circonferenza dopo aver fissato il primo punto e pertanto fissare uno dei due estremi e generare casualmente l'altro estremo come un punto sulla circonferenza. Lo spazio degli eventi elementari è

$$\Omega = \mathbb{S}^1 = \{x \in \mathbb{R}^2 \text{ tale che } |x| = 1\}.$$

Utilizziamo come misura di probabilità la lunghezza degli archi divisa per la lunghezza della circonferenza. Dalla Figura 2.7 notiamo che la probabilità che la corda sia più lunga del lato del triangolo equilatero inscritto è $\frac{1}{3}$.




FIGURA 2.7. L'arco colorato rappresenta l'evento in cui la corda è più lunga del lato del triangolo equilatero inscritto.

Proposta di soluzione 2. Per descrivere la corda scelta a caso nel cerchio è sufficiente generare un angolo, e un punto sul raggio con l'angolo generato. Si traccia quindi la corda ortogonale al raggio passante per il punto.

Lo spazio degli eventi elementari è

$$\Omega = [0, 2\pi) \times [0, 1) = \{(\theta, r), \theta \in [0, 2\pi), r \in (0, 1)\}.$$

Come misura di probabilità utilizziamo la distanza dal centro (l'angolo è indifferente perché si può ruotare la figura). Dalla Figura 2.8 notiamo che la probabilità che la corda sia più lunga del lato del triangolo equilatero inscritto è $\frac{1}{2}$.




FIGURA 2.8. Il segmento colorato rappresenta i valori di r per cui la corda è più lunga del lato del triangolo equilatero inscritto.

Proposta di soluzione 3. Per descrivere la corda scelta a caso nel cerchio è sufficiente generare un punto a caso nel cerchio, disegnare il raggio passante per il punto e tracciare la corda ortogonale al raggio passante per il punto.

Lo spazio degli eventi elementari è

$$\Omega = \{x \in \mathbb{R}^2 \text{ tale che } |x| \leq 1\}.$$

La misura di probabilità che usiamo è l'area divisa per π . Dalla Figura 2.9 osserviamo che la probabilità è $\frac{1}{4}$.




FIGURA 2.9. Il cerchio colorato rappresenta i punti x per cui la corda è più lunga del lato del triangolo equilatero inscritto.

Quale delle tre soluzioni proposte è quella giusta? In realtà sono tutte soluzioni corrette. L'errore vero è commesso nell'ambiguità della domanda. Dire che una corda è "scelta a caso" vuol dire poco se non viene spiegato qual è la distribuzione di probabilità che viene utilizzata per generare le corde. Nella Figura 2.10 si mostra come siano diverse le distribuzioni delle corde generate casualmente con i tre metodi.




FIGURA 2.10. Distribuzioni delle corde con le tre soluzioni proposte. In tutti e tre casi sono generate 500 corde. Si può notare come la distribuzione delle corde sia diversa.

► Riguardo a questo argomento, si consiglia il video di divulgazione del canale Numberphile con Grant Sanderson (3Blue1Brown) al seguente link: <https://youtu.be/mZBwsm6B280?si=JA09rST5xvVdlysp>. □

⚠ La probabilità dell'unione è uguale alla somma delle probabilità quando gli eventi sono mutuamente disgiunti. Se gli eventi non sono mutuamente disgiunti, la formula non vale, come mostra il seguente esempio.

ESEMPIO 2.25. (Lancio di un dado) Calcoliamo la probabilità che nel lancio di un dado esca un numero pari oppure un numero minore o uguale a 3. Lo spazio degli eventi elementari è

$$\Omega = \{1, 2, 3, 4, 5, 6\}.$$

Consideriamo gli eventi

$$A = \text{“l'esito è pari”} = \{2, 4, 6\}, \quad B = \text{“l'esito è } \leq 3\text{”} = \{1, 2, 3\}.$$

Si ha che

$$\mathbb{P}(A) = \frac{1}{2}, \quad \mathbb{P}(B) = \frac{1}{2},$$

tuttavia

$$\mathbb{P}(A \cup B) = \frac{5}{6} \neq \frac{1}{2} + \frac{1}{2}.$$

□

C'è una formula che vale anche per calcolare la probabilità dell'unione di due eventi anche se non sono disgiunti.

PROPOSIZIONE 2.26. (*Principio di inclusione-esclusione per due eventi*) Siano A e B due eventi. Allora $\mathbb{P}(A \cup B) = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B)$.

DIMOSTRAZIONE. Osserviamo che A e $B \setminus (A \cap B)$ sono disgiunti, che $A \cap B \subset B$ e che $A \cup B = A \cup (B \setminus (A \cap B))$. Si veda la Figura 2.11.




FIGURA 2.11. Diagramma di ausilio alla dimostrazione.

Per l'Osservazione 2.18 abbiamo che

$$\mathbb{P}(A \cup B) = \mathbb{P}(A \cup (B \setminus (A \cap B))) = \mathbb{P}(A) + \mathbb{P}(B \setminus (A \cap B)) = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B).$$

Questo conclude la dimostrazione. \square

PROPOSIZIONE 2.27. (*Principio di inclusione-esclusione per tre eventi*) Siano A, B, C tre eventi. Allora

$$\mathbb{P}(A \cup B \cup C) = \mathbb{P}(A) + \mathbb{P}(B) + \mathbb{P}(C) - \mathbb{P}(A \cap B) - \mathbb{P}(A \cap C) - \mathbb{P}(B \cap C) + \mathbb{P}(A \cap B \cap C).$$

DIMOSTRAZIONE. Applichiamo la Proposizione 2.26 agli insiemi $A \cup B$ e C , agli insiemi A e B , e agli insiemi $A \cap C$ e $B \cap C$ per avere che

$$\begin{aligned} \mathbb{P}(A \cup B \cup C) &= \mathbb{P}(A \cup B) + \mathbb{P}(C) - \mathbb{P}((A \cup B) \cap C) \\ &= \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B) + \mathbb{P}(C) - \mathbb{P}((A \cap C) \cup (B \cap C)) \\ &= \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B) + \mathbb{P}(C) - \mathbb{P}(A \cap C) - \mathbb{P}(B \cap C) + \mathbb{P}(A \cap B \cap C). \end{aligned}$$

\square

La formula generale è la seguente.

PROPOSIZIONE 2.28. (*Principio di inclusione-esclusione*) Siano A_1, \dots, A_n eventi. Allora

$$\mathbb{P}\left(\bigcup_{i=1}^n A_i\right) = \sum_{k=1}^n \sum_{\substack{I \subset \{1, \dots, n\} \\ \#I=k}} (-1)^{k+1} \mathbb{P}\left(\bigcap_{i \in I} A_i\right).$$

DIMOSTRAZIONE. \clubsuit La dimostrazione è lasciata per esercizio. Si può utilizzare il principio di induzione matematica. \square

ESERCIZIO 2.29. Lanci due monete. Qual è la probabilità che escano due teste? (Si assumano i possibili eventi elementari equiprobabili). \square

2.1.1. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 2.30. Una carta viene pescata da un mazzo di carte francesi da 52 carte. Calcolare la probabilità che la carta pescata sia: a) un asso; b) un $J\heartsuit$; c) un $3\clubsuit$ o un $6\diamondsuit$; d) una carta di \heartsuit ; e) di qualunque seme fuorché \heartsuit ; f) un 10 oppure una carta di \spadesuit ; g) né un 4 né una carta di \clubsuit . \square

ESERCIZIO 2.31. In un cassetto ci sono 6 calzini: 2 rossi, 2 blu, 2 viola. È buio, quindi non puoi distinguerli. Prendi un calzino a caso e poi un altro dai rimanenti 5. Qual è la probabilità di avere due calzini dello stesso colore? \square

ESERCIZIO 2.32. Sei su un'isola deserta con un'altra persona. C'è un ultimo frutto rimasto sull'isola e ve lo giocate a dadi. Tirate due dadi e:

- (1) se il numero più grande è 1,2,3 o 4 vince il giocatore 1;
- (2) se il numero più grande è 5 o 6 vince il giocatore 2.

Quale giocatore preferiresti essere? \square

ESERCIZIO 2.33. Considera i tre dadi con le seguenti facce: $A : 2, 2, 4, 4, 9, 9$; $B : 1, 1, 6, 6, 8, 8$; $C : 3, 3, 5, 5, 7, 7$. Il dado A ha una probabilità $1/3$ di ottenere un 9, per esempio.

- Mostrare che il dado A è “più forte” del dado B (nel senso che ha una probabilità maggiore di ottenere un numero più alto).
- Mostrare che il dado B è “più forte” del dado C .
- Cosa si può dire della relazione tra il dado C e il dado A ?

\square

ESERCIZIO 2.34. Tre persone stanno giocando a un gioco che coinvolge cappelli bianchi e neri. All'inizio del gioco, ad ogni persona viene assegnato casualmente un colore del cappello, nero o bianco. Tutte le possibili assegnazioni sono equiprobabili.

Immagina che le persone non possano vedere cosa c'è sulla loro testa e osservino solo i colori dei cappelli dei loro due amici. Non è consentita alcuna comunicazione. I giocatori devono contemporaneamente indovinare il colore del proprio cappello (o rifiutarsi di indovinare). L'intero gruppo vince un premio se almeno uno di loro indovina correttamente e nessuno indovina in modo errato.

Supponiamo che la squadra adotti una strategia da “bastian contrario”: chiunque osservi due cappelli bianchi tirerà a indovinare che il proprio cappello è nero; chiunque osservi due cappelli neri tirerà a indovinare che il proprio cappello è bianco; e chiunque osservi qualcos'altro si rifiuterà di indovinare. All'inizio del gioco (prima dell'assegnazione dei colori del cappello), qual è la probabilità che il gruppo vinca il premio? \square

ESERCIZIO 2.35. Stai assumendo un nuovo CEO e tre persone hanno fatto domanda per la posizione. Il tuo obiettivo è massimizzare la probabilità di assumere il migliore dei tre, ma non sai in anticipo quale sia il candidato migliore.

Supponiamo di dover intervistare i candidati in sequenza (per qualche motivo non è possibile intervistarli in parallelo) e di prendere una decisione immediata di assunzione/rifiuto alla fine di ogni colloquio. L'unica informazione su cui puoi basare la tua decisione è come valuti il candidato attuale rispetto ai candidati precedenti: sai se è il migliore tra le persone che hai intervistato finora, ma non sai come si rapporta alle persone con cui non hai ancora parlato. (Per semplicità, supponi che i candidati non rifiutino mai la tua offerta.)

Ad esempio, potresti rifiutare il primo candidato, quindi intervistare e assumere il secondo candidato, nel qual caso non incontrerai mai la terza persona nella sequenza.

Sotto la strategia di assunzione ottimale, qual è la tua probabilità di assumere il miglior candidato? \square

ESERCIZIO 2.36. Considera un cerchio di diametro d inscritto in un quadrato di lato d . Scegliendo un punto uniformemente a caso nel quadrato, qual è la probabilità che capiti nel cerchio? \square

ESERCIZIO 2.37. In un gioco del luna park, un giocatore lancia una moneta da 1 centesimo su un tavolo quadratato. Se il centesimo cade interamente all'interno di un quadratino, il giocatore vince 5 centesimi, altrimenti perde il centesimo giocato. Qual è la probabilità di vincere sapendo che il diametro della moneta è $\frac{3}{4}$ del lato dei quadratini? \square

2.2. Enumerazione

Principio fondamentale del calcolo combinatorio. Se si effettuano k scelte e per la prima scelta sono disponibili n_1 oggetti, per la seconda scelta sono disponibili n_2 oggetti, ..., per la k -esima scelta sono disponibili n_k oggetti, allora le scelte possibili sono in tutto $n_1 n_2 \cdots n_k$.

Disposizioni. Introduciamo il concetto di disposizione.

DEFINIZIONE 2.38. (Disposizioni con ripetizioni) Sia $A = \{a_1, \dots, a_n\}$ un insieme di n elementi. Una *disposizione con possibili ripetizioni di k elementi scelti da A* è una k -upla $(\omega_1, \dots, \omega_k)$ dove $\omega_i \in A$. \square

ESEMPIO 2.39. Cinque persone sono sedute a un tavolo in pizzeria. Il menu prevede le seguenti 7 pizze:

- Marinara
- Margherita
- Diavola
- Capricciosa
- Crudaiola
- Rape e salsiccia di Norcia
- Fumè

Quante sono le possibili cene distinte che possono essere fatte dal tavolo? (Due persone possono anche ordinare la stessa pizza)

La prima persona può scegliere tra 7 pizze. La seconda persona anche. Così fino alla quinta. In tutto, le cene possibili sono

$$7 \cdot 7 \cdot 7 \cdot 7 \cdot 7 = 7^5 = 16807.$$

Si chiamano disposizioni perché l'ordine in cui le scelte sono disposte è rilevante. Infatti, la configurazione

(Margherita, Margherita, Crudaiola, Diavola, Margherita)

è diversa da

(Margherita, Diavola, Crudaiola, Margherita, Margherita)

perché le persone ordinano pizze diverse (anche se complessivamente le pizze ordinate sono le stesse!). \square

OSSERVAZIONE 2.40. In generale, il numero di disposizioni con possibili ripetizioni di k elementi scelti da un insieme di n elementi è

$$\underbrace{n \cdots n}_{k \text{ volte}} = n^k.$$

\square

DEFINIZIONE 2.41. (Disposizioni senza ripetizioni) Sia $A = \{a_1, \dots, a_n\}$ un insieme di n elementi. Una *disposizione senza ripetizioni di k elementi scelti da A* è una k -upla $(\omega_1, \dots, \omega_k)$ dove $\omega_i \in A$ sono tali che $\omega_i \neq \omega_j$ per $i \neq j$. \square

ESEMPIO 2.42. Cinque persone sono sedute a un tavolo in pizzeria. Decidono di ordinare una pizza a testa, ma condivideranno un quarto di pizza a testa in modo da poter assaggiare altri gusti. Decidono quindi di non ordinare due pizze uguali al tavolo. Le pizze sono quelle dell'Esempio 2.39. Il numero di ordinazioni possibili si calcola così:

- La prima persona può scegliere tra 7 pizze.
- La seconda persona può scegliere tra 6 pizze. (Non può scegliere la pizza scelta dal primo).
- La terza persona può scegliere tra 5 pizze.
- La quarta persona può scegliere tra 4 pizze.
- La quinta persona può scegliere tra 3 pizze.

In tutto, le ordinazioni possibili sono

$$7 \cdot 6 \cdot 5 \cdot 4 \cdot 3 = 2520.$$

\square

OSSERVAZIONE 2.43. Il numero di disposizioni senza ripetizioni di k elementi scelti da un insieme di n elementi è

$$n(n-1) \cdots (n-k+1).$$

Introduciamo il fattoriale di un numero naturale, definito dalla relazione ricorsiva

$$\begin{cases} k! = k(k-1)!, \\ 0! = 1. \end{cases}$$

ovvero

$$k! = k(k-1) \cdots 2 \cdot 1.$$

Allora il numero di disposizioni senza ripetizioni di k elementi scelti da un insieme di n elementi si può scrivere nel seguente modo:

$$n(n-1) \cdots (n-k+1) = \frac{n!}{(n-k)!}.$$

\square

Permutazioni. Introduciamo il concetto di permutazione.

DEFINIZIONE 2.44. Sia $A = \{a_1, \dots, a_n\}$ un insieme di n elementi. Una *permutazione* di elementi di A è una disposizione senza ripetizioni di n elementi scelti da A , ovvero una n -upla $(\omega_1, \dots, \omega_n)$ dove $\omega_i \in A$ sono tali che $\omega_i \neq \omega_j$ per $i \neq j$. \square

OSSERVAZIONE 2.45. Il numero di permutazioni di un insieme di n elementi è $n!$. \square

ESEMPIO 2.46. In quanti modi si possono ordinare i numeri dell'insieme $\{1, 2, 3, 4\}$? In $4! = 4 \cdot 3 \cdot 2 \cdot 1 = 24$ modi. Elenchiamoli tutti (lo facciamo solo questa volta):

$$\begin{aligned} &(1, 2, 3, 4), (1, 2, 4, 3), (1, 3, 2, 4), (1, 3, 4, 2), (1, 4, 2, 3), (1, 4, 3, 2), \\ &(2, 1, 3, 4), (2, 1, 4, 3), (2, 3, 1, 4), (2, 3, 4, 1), (2, 4, 1, 3), (2, 4, 3, 1), \\ &(3, 1, 2, 4), (3, 1, 4, 2), (3, 2, 1, 4), (3, 2, 4, 1), (3, 4, 1, 2), (3, 4, 2, 1), \\ &(4, 1, 2, 3), (4, 1, 3, 2), (4, 2, 1, 3), (4, 2, 3, 1), (4, 3, 1, 2), (4, 3, 2, 1). \end{aligned}$$

\square

ESEMPIO 2.47. La probabilità che in un gruppo di $k = 23$ persone almeno due persone condividano lo stesso giorno di compleanno è più del 50%. (Supponendo che la distribuzione dei compleanni sia uniforme).

Per mostrarlo, modelliamo questo esperimento probabilistico nel seguente modo. Consideriamo l'insieme di tutti i giorni in un anno $\{1, 2, 3, 4, \dots, 365\}$ e poniamo $n = 365$. Una possibile configurazione di compleanni nel gruppo di k persone è una disposizione, con possibili ripetizioni, di $k = 23$ elementi scelti da un insieme di $n = 365$ elementi. Definiamo lo spazio degli eventi elementari

$$\Omega = \{(\omega_1, \dots, \omega_k) \text{ con } \omega_i \in \{1, 2, \dots, 365\}\}.$$

Osserviamo che $\#\Omega = n^k = 365^{23}$. Poiché stiamo assumendo che la distribuzione dei compleanni sia uniforme,

$$\mathbb{P}(\{(\omega_1, \dots, \omega_k)\}) = \frac{1}{365^{23}}.$$

Consideriamo l'evento

$$A = \text{“almeno due persone condividono lo stesso compleanno”}.$$

Non è semplicissimo calcolare direttamente la probabilità di A . Tuttavia, possiamo calcolare con semplicità la probabilità del complementare. Infatti,

$$\Omega \setminus A = \text{“tutte le persone hanno compleanni distinti”}$$

è costituito da tutte le disposizioni senza ripetizioni

$$\Omega \setminus A = \{(\omega_1, \dots, \omega_k) \text{ con } \omega_i \in \{1, 2, \dots, 365\} \text{ tale che } \omega_i \neq \omega_j \text{ per } i \neq j\}.$$

Osserviamo che $\#(\Omega \setminus A) = \frac{n!}{(n-k)!} = \frac{365!}{(365-23)!}$. Allora

$$\mathbb{P}(A) = 1 - \mathbb{P}(\Omega \setminus A) = 1 - \frac{365!}{(365-23)! 365^{23}} = 1 - \underbrace{\frac{365 \cdot 364 \cdots 343}{365 \cdot 365 \cdots 365}}_{k \text{ volte}} \simeq 50.73\% > 50\%.$$

\square

Combinazioni semplici. Introduciamo il concetto di combinazioni semplici.

DEFINIZIONE 2.48. Sia $A = \{a_1, \dots, a_n\}$ un insieme di n elementi. Una *combinazione semplice* di k elementi di A è un sottoinsieme di k elementi distinti di A , ovvero $\{\omega_1, \dots, \omega_k\}$, dove $\omega_i \in A$ sono tali che $\omega_i \neq \omega_j$ per $i \neq j$. \square

ESEMPIO 2.49. Cinque persone sono sedute a un tavolo in pizzeria. Il menu prevede le 7 pizze elencate nell'Esempio 2.39. Le persone vogliono condividere tutte le pizze, quindi non è importante chi ordina cosa, ma le pizze devono essere tutte diverse. Quante sono le possibili ordinazioni? Sono date dalle combinazioni semplici di 5 elementi scelti da 7. Possiamo pensare a queste combinazioni in questo modo. Consideriamo le disposizione senza ripetizioni di 5 elementi scelti fra 7. Sappiamo contarle, sono $\frac{7!}{2!}$. Il problema è che alcune di queste corrispondono alla stessa combinazione, poiché l'ordine non è importante per le combinazioni. Ad esempio, la disposizione

(Margherita, Fumè, Crudaiola, Diavola, Marinara)

e la disposizione

(Fumè, Crudaiola, Diavola, Marinara, Margherita)

corrispondono entrambe alla combinazione

$\{\text{Marinara, Margherita, Diavola, Crudaiola, Fumè}\}$.

Quante sono in tutto le disposizioni che corrispondono alla stessa combinazione? Sono pari al numero di permutazioni di 5 elementi (ovvero il numero di modi in cui si possono riordinare 5 elementi), ovvero $5!$. Concludiamo che il numero di combinazioni semplici di 5 elementi scelti fra 7 è

$$\frac{7!}{5!2!} = \frac{7 \cdot 6}{2} = 7 \cdot 3 = 21.$$

\square

OSSERVAZIONE 2.50. Il numero di combinazioni semplici di k elementi scelti fra n è dato da

$$\frac{n!}{k!(n-k)!}.$$

\square

Poiché il numero di combinazioni semplici di k elementi scelti fra n compare spesso nella probabilità, viene dato un nome a questa quantità. Il numero

$$\binom{n}{k} := \frac{n!}{k!(n-k)!}$$

è detto *coefficiente binomiale*.

OSSERVAZIONE 2.51. Il nome *coefficiente binomiale* ha un motivo. Compare nel calcolo dello sviluppo di un binomio. Infatti

$$(a+b)^n = \underbrace{(a+b)(a+b) \cdots (a+b)}_{n \text{ volte}}. \quad (2.1)$$




FIGURA 2.13. Niccolò Fontana, detto Tartaglia (1499-1557).^a Ha individuato una formula risolutiva per le equazioni di terzo grado, ma è ricordato più per il triangolo che porta il suo nome.

^aFonte dell'immagine: [https://commons.wikimedia.org/wiki/File:Portret_van_Niccolo_Tartaglia_Nicolavs_Tartaglia_Brixianvs_\(titel_op_object\)_Portretten_van_beroemde_Europese_geleerden_\(serietitel\)_Virorum_doctorum_de_Disciplinis_benemerentium_effigies_\(serietitel\),_RP-P-1909-4459.jpg](https://commons.wikimedia.org/wiki/File:Portret_van_Niccolo_Tartaglia_Nicolavs_Tartaglia_Brixianvs_(titel_op_object)_Portretten_van_beroemde_Europese_geleerden_(serietitel)_Virorum_doctorum_de_Disciplinis_benemerentium_effigies_(serietitel),_RP-P-1909-4459.jpg)

2.2.1. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 2.53. In una città ci sono 5 hotel. Se un giorno 3 persone prenotano un hotel ciascuno, qual è la probabilità che siano ospitati da 3 hotel differenti? (Si supponga che tutte le configurazioni possibili di prenotazioni siano equiprobabili)

ESERCIZIO 2.54. Una pompa idraulica di un grosso impianto industriale è dotata di 7 filtri dello stesso tipo la cui manutenzione deve essere fatta gli ultimi tre giorni di ogni mese. Se la manutenzione di ognuno dei 7 filtri è assegnata in modo casuale ad ognuno dei tre giorni, calcolare: a) la probabilità che tutte le manutenzioni capitino in un solo giorno; b) la probabilità che ad ogni giorno venga assegnata almeno una manutenzione.

ESERCIZIO 2.55. La costruzione di 9 apparecchiature deve essere programmata nell'arco dei 5 giorni lavorativi di una settimana. Ogni singola apparecchiatura richiede un intero giorno di lavoro ma più apparecchiature possono essere costruite in un singolo giorno. La costruzione di ognuna delle 9 apparecchiature è assegnata in modo casuale ad ognuno dei 5 giorni lavorativi della settimana. Si determinino: a) la probabilità che al primo e al secondo giorno sia assegnata almeno 1 apparecchiatura; b) la probabilità che al quinto giorno venga assegnata esattamente una apparecchiatura.

ESERCIZIO 2.56. Un torneo di tennis a eliminazione diretta ha 8 giocatori ed è strutturato in quarti di finale–semifinale–finale. Supponiamo che il miglior giocatore del torneo vinca sempre contro il secondo migliore, che a sua volta vince sempre contro i restanti. All’inizio del torneo i match sono assegnati casualmente. Qual è la probabilità che il secondo migliore si classifichi secondo?

ESERCIZIO 2.57. Qual è la probabilità di ricevere 5 carte dello stesso seme da un mazzo di 52 carte francesi (4 semi)?

ESERCIZIO 2.58. Un’urna contiene 15 biglie di cui 5 rosse, 3 blu, 7 verdi. Si pesca casualmente 6 biglie. Qual è la probabilità che almeno 3 delle biglie siano rosse ed esattamente 2 biglie siano verdi?

ESERCIZIO 2.59. Un’urna contiene biglie bianche e biglie nere. Quando due biglie vengono estratte a caso, la probabilità che entrambe siano bianche è $\frac{1}{2}$. Qual è il numero minimo di biglie che possono esserci nell’urna?


ESERCIZIO 2.60. Se una moneta viene lanciata 100 volte, qual è la probabilità che esca esattamente 50 volte testa?

ESERCIZIO 2.61. Una società di consulenza ha ricevuto da parte di un ente pubblico il compito di selezionare i membri di una commissione che dovrà valutare i progetti presentati per vincere l’appalto di una grande opera pubblica. La commissione deve essere composta da sette persone di cui tre dell’accademia, due dell’industria e due esponenti della maggioranza politica al governo nel comune in questione. La società deve scegliere i membri da una rosa di candidati composta da otto accademici/che, sei industriali e cinque esponenti politici della maggioranza. a) In quanti modi diversi può essere formata la commissione? b) Se dei sei industriali quattro sono donne, trovare la probabilità che nella commissione vi siano due di queste donne.

ESERCIZIO 2.62. Da 5 probabilisti/e e 6 economisti/e, deve essere formata una commissione composta da 3 probabilisti/e e 2 economisti/e, scegliendo in modo casuale uniforme. Qual è la probabilità che: a) 2 particolari probabilisti/e capitino nella commissione; b) un particolare economista non capiti nella commissione?

ESERCIZIO 2.63. Su un sito di incontri, gli utenti possono selezionare 5 su 24 aggettivi per descrivere se stessi. C’è un “match” tra due utenti se coincidono almeno 4 degli aggettivi scelti. Se Alice e Bob scelgono a caso gli aggettivi, qual è la probabilità che formino un “match”?

ESERCIZIO 2.64. Consideriamo una griglia quadrettata con quadretti di lato 1 nel piano cartesiano. Un topo parte dall’origine $(0, 0)$ e un pezzo di formaggio è nell’angolo opposto del rettangolo $(7, 4)$. Il topo si muove all’interno del rettangolo di lati 7 e 4, scegliendo uniformemente a caso un tragitto che lo connette con il formaggio e che consiste in passi consequenziali di ampiezza 1 verso est oppure verso nord. Una trappola è nel punto $(5, 2)$. Qual è la probabilità che il topo arrivi al formaggio senza cadere nella trappola?



□

2.3. Probabilità condizionata ed eventi indipendenti

Probabilità condizionata. Per introdurre il concetto di probabilità condizionata, studiamo il seguente esempio.

ESEMPIO 2.65. Si hanno a disposizione due urne, l'urna u_1 e l'urna u_2 . L'urna u_1 contiene 2 palline nere e 1 pallina bianca. L'urna u_2 contiene 1 pallina nera e 2 bianche. Si veda la Figura 2.65.




FIGURA 2.14. Urne utilizzate nell'Esempio 2.65.

Viene scelta uniformemente a caso un'urna tra u_1 e u_2 . Dall'urna scelta viene estratta uniformemente a caso una pallina.

Se sappiamo che l'urna scelta è u_1 , la probabilità che la pallina sia nera è $\frac{2}{3}$. Se sappiamo che l'urna scelta è u_2 , la probabilità che la pallina sia nera è $\frac{1}{3}$. Questo vuol dire che gli eventi “viene estratta l'urna u_1 ” e “viene estratta l'urna u_2 ” condizionano la probabilità dell'evento “viene estratta una pallina nera”. □



FIGURA 2.15. *xkcd* 1374. URN. Credits: <https://xkcd.com/1374/>

DEFINIZIONE 2.66. (Probabilità condizionata) Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Siano A, B due eventi con $\mathbb{P}(B) > 0$. La *probabilità di A condizionata dall'evento B* è il numero

$$\mathbb{P}(A|B) := \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}.$$

□

La probabilità di A condizionata dall'evento B rappresenta la probabilità che si verifichi l'evento A se sappiamo che si è verificato l'evento B . Infatti è la probabilità che si verifichino contemporaneamente i due eventi, rapportata alla probabilità che si verifichi B .

OSSERVAZIONE 2.67. Se $\mathbb{P}(B) > 0$, allora $\mathbb{P}(\cdot|B)$ è una misura di probabilità. Infatti

$$\mathbb{P}(\Omega|B) = \frac{\mathbb{P}(\Omega \cap B)}{\mathbb{P}(B)} = \frac{\mathbb{P}(B)}{\mathbb{P}(B)} = 1.$$

Inoltre, se $(A_i)_{i \in \mathbb{N}} \subset \mathcal{F}$ sono tali che $A_i \cap A_j = \emptyset$ per $i \neq j$, allora $(A_i \cap B) \cap (A_j \cap B) = \emptyset$ e pertanto

$$\mathbb{P}\left(\bigcup_{i \in \mathbb{N}} A_i \mid B\right) = \frac{\mathbb{P}\left(\bigcup_{i \in \mathbb{N}} A_i \cap B\right)}{\mathbb{P}(B)} = \frac{\sum_{i \in \mathbb{N}} \mathbb{P}(A_i \cap B)}{\mathbb{P}(B)} = \sum_{i \in \mathbb{N}} \mathbb{P}(A_i|B).$$

□

OSSERVAZIONE 2.68. Siano A e B due eventi con $\mathbb{P}(B) > 0$. Utilizzando la definizione di probabilità condizionata possiamo calcolare la probabilità che si verifichino contemporaneamente A e B :

$$\mathbb{P}(A \cap B) = \mathbb{P}(A|B)\mathbb{P}(B).$$

▲ Spesso si sente la frase “la probabilità che due eventi si verifichino contemporaneamente è il prodotto delle probabilità”. Questa frase non è sempre vera! Vedremo che è vera per eventi indipendenti! Si consiglia di usare sempre la formula $\mathbb{P}(A \cap B) = \mathbb{P}(A|B)\mathbb{P}(B)$ e poi valutare l’indipendenza degli eventi. Approfondiremo a breve. \square

ESEMPIO 2.69. Tornando all’Esempio 2.65, possiamo descrivere l’esperimento con lo spazio degli eventi elementari

$$\Omega = \{(\omega_1, \omega_2) \text{ dove } \omega_1 \in \{u_1, u_2\}, \omega_2 \in \{b, n\}\}.$$

Descriviamo gli eventi:

$$U_1 = \text{“viene estratta l’urna 1”} = \{(u_1, b), (u_1, n)\},$$

$$U_2 = \text{“viene estratta l’urna 2”} = \{(u_2, b), (u_2, n)\},$$

$$B = \text{“viene estratta una pallina bianca”} = \{(u_1, b), (u_2, b)\},$$

$$N = \text{“viene estratta una pallina nera”} = \{(u_1, n), (u_2, n)\}.$$

Utilizzando la probabilità condizionata, l’esperimento descritto si riassume come segue:

$$\mathbb{P}(U_1) = \frac{1}{2}, \quad \mathbb{P}(U_2) = \frac{1}{2},$$

$$\mathbb{P}(B|U_1) = \frac{1}{3}, \quad \mathbb{P}(B|U_2) = \frac{2}{3}.$$

Domanda: qual è la probabilità di estrarre una pallina bianca alla fine di tutto l’esperimento?

Osservando la figura ci aspettiamo che sia $\frac{1}{2}$. È vero? Forse dipende dalla probabilità di scelta dell’urna? Rispondiamo a questa domanda con il seguente teorema. \square

Il teorema della probabilità totale permette di calcolare la probabilità di un evento (totale) quando sono note le probabilità del verificarsi dell’evento sapendo che si verificano altri eventi che decompongono l’intero spazio degli eventi elementari.

TEOREMA 2.70 (Teorema della probabilità totale). *Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Sia $(B_i)_{i \in \mathbb{N}}$ una partizione di Ω , ovvero una collezione di eventi tali che $B_i \cap B_j = \emptyset$ per $i \neq j$ e $\Omega = \bigcup_{i \in \mathbb{N}} B_i$. Sia A un evento. Allora*

$$\mathbb{P}(A) = \sum_{i \in \mathbb{N}} \mathbb{P}(A|B_i)\mathbb{P}(B_i).$$

DIMOSTRAZIONE. Dalle ipotesi segue, a maggior ragione, che $(A \cap B_i) \cap (A \cap B_j) = \emptyset$. Inoltre

$$A = A \cap \Omega = A \cap \bigcup_{i \in \mathbb{N}} B_i = \bigcup_{i \in \mathbb{N}} (A \cap B_i).$$

Si veda la Figura 2.3 come riferimento. Per la σ -additività della misura di probabilità e per l’Osservazione 2.68 sulla probabilità dell’intersezione segue che

$$\mathbb{P}(A) = \mathbb{P}\left(\bigcup_{i \in \mathbb{N}} (A \cap B_i)\right) = \sum_{i \in \mathbb{N}} \mathbb{P}(A \cap B_i) = \sum_{i \in \mathbb{N}} \mathbb{P}(A|B_i)\mathbb{P}(B_i).$$




FIGURA 2.16. Decomposizione di Ω utilizzando la collezione di eventi $(B_i)_{i \in \mathbb{N}}$ e conseguente decomposizione di A utilizzando la collezione di eventi $(A \cap B_i)_{i \in \mathbb{N}}$.

□

ESEMPIO 2.71. Tornando all'Esempio 2.69, osserviamo che $U_1 \cap U_2 = \emptyset$ e $U_1 \cup U_2 = \Omega$. Per il teorema della probabilità totale abbiamo che la probabilità di estrarre una pallina bianca è

$$\mathbb{P}(B) = \mathbb{P}(B|U_1)\mathbb{P}(U_1) + \mathbb{P}(B|U_2)\mathbb{P}(U_2) = \frac{1}{3} \cdot \frac{1}{2} + \frac{2}{3} \cdot \frac{1}{2} = \frac{1}{2}.$$

Domanda: eseguiamo l'esperimento. Osserviamo che è stata estratta una pallina bianca. Qual è la probabilità che l'urna scelta casualmente sia stata l'urna u_2 ?

Per rispondere a questo tipo di domande si utilizza il Teorema di Bayes. □

TEOREMA 2.72 (Formula di Bayes con due eventi). *Siano A e B due eventi con $\mathbb{P}(A) > 0$ e $\mathbb{P}(B) > 0$. Allora*

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

DIMOSTRAZIONE. La formula segue immediatamente dalla definizione di probabilità condizionata e dall'Osservazione 2.68 sulla probabilità dell'intersezione:

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

□



FIGURA 2.17. Thomas Bayes (1702-1761).^a È noto soprattutto per il suo teorema, che è stato pubblicato postumo.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Thomas_Bayes.gif

OSSERVAZIONE 2.73. Come abbiamo visto, la dimostrazione della formula di Bayes è praticamente banale. Nonostante ciò, formula di Bayes è una delle formule più importanti della probabilità (forse della matematica?) ed una delle più utilizzate nelle applicazioni. Va interpretata così. Abbiamo due eventi A e B . Per l'evento B conosciamo una probabilità *a priori*. Facciamo degli esperimenti e delle osservazioni. Osserviamo che si è verificato l'evento A . Questo fatto ci permette di aggiornare la probabilità che si verifichi l'evento B , ovvero la probabilità di B *a posteriori*. Come aggiorniamo la probabilità? Con la formula di Bayes:

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

▲ Se non sai la formula di Bayes, non puoi passare l'esame di Probabilità e Statistica con un buon voto. □

ESEMPIO 2.74. Torniamo all'Esempio 2.71. Eseguiamo l'esperimento. Sappiamo che è stata estratta una pallina bianca. Qual è la probabilità che sia stata scelta l'urna u_2 ? È più alta di $\frac{1}{2}$? Ricordiamo che, per il teorema della probabilità totale

$$\mathbb{P}(B) = \mathbb{P}(B|U_1)\mathbb{P}(U_1) + \mathbb{P}(B|U_2)\mathbb{P}(U_2).$$

Calcoliamo la probabilità *a posteriori* utilizzando la formula di Bayes

$$\mathbb{P}(U_2|B) = \frac{\mathbb{P}(B|U_2)\mathbb{P}(U_2)}{\mathbb{P}(B)} = \frac{\mathbb{P}(B|U_2)\mathbb{P}(U_2)}{\mathbb{P}(B|U_1)\mathbb{P}(U_1) + \mathbb{P}(B|U_2)\mathbb{P}(U_2)} = \frac{\frac{2}{3} \cdot \frac{1}{2}}{\frac{1}{3} \cdot \frac{1}{2} + \frac{2}{3} \cdot \frac{1}{2}} = \frac{2}{3} > \frac{1}{2}.$$

□

ESEMPIO 2.75. Per individuare la presenza di una malattia viene effettuato un test di screening. Il test ha:

- *sensibilità* 97%: se la malattia è presente, il test è positivo con 97% di probabilità (falsi negativi 3%);
- *specificità* 90%: se la malattia non è presente, il test è negativo con 90% di probabilità (falsi positivi 10%).

A priori, si stima che lo 0.2% delle persone abbia la malattia.

Un individuo effettua il test. È positivo. Qual è la probabilità che abbia la malattia?

Scriviamo lo spazio degli eventi elementari:

$$\Omega = \{(m, +), (m, -), (s, +), (s, -)\},$$

dove “ m ” vuol dire “malato”, “ s ” vuol dire “sano”, “+” vuol dire “test positivo”, “-” vuol dire “test negativo”. Consideriamo gli eventi

$$M = \text{“il soggetto è malato”} = \{(m, +), (m, -)\},$$

$$S = \text{“il soggetto è sano”} = \{(s, +), (s, -)\},$$

$$P = \text{“il test è positivo”} = \{(m, +), (s, +)\},$$

$$N = \text{“il soggetto è negativo”} = \{(m, -), (s, -)\}.$$

Per la malattia sappiamo che

$$\mathbb{P}(M) = 0.2\%, \quad \mathbb{P}(S) = 1 - \mathbb{P}(M) = 1 - 0.2\% = 99.8\%.$$

Le caratteristiche del test sono

$$\mathbb{P}(P|M) = 97\%, \quad \mathbb{P}(N|S) = 90\%.$$

Da queste possiamo anche calcolare, usando il fatto che la probabilità condizionata è una misura di probabilità,

$$\mathbb{P}(N|M) = 1 - \mathbb{P}(P|M) = 3\%, \quad \mathbb{P}(P|S) = 1 - \mathbb{P}(N|S) = 10\%.$$

Calcoliamo con la formula di Bayes la probabilità di avere la malattia sapendo che il test è positivo:

$$\mathbb{P}(M|P) = \frac{\mathbb{P}(P|M)\mathbb{P}(M)}{\mathbb{P}(P|M)\mathbb{P}(M) + \mathbb{P}(P|S)\mathbb{P}(S)} = \frac{97\% \cdot 0.2\%}{97\% \cdot 0.2\% + 10\% \cdot 99.8\%} \simeq 1.91\%.$$

La probabilità 1.91% può sembrare piccola. Questo è dovuto al fatto che la probabilità *a priori* è molto piccola. Tuttavia, se le conseguenze della malattia sono elevati, 1.91% potrebbe essere quantificato come un rischio medio e elevato, a seconda della malattia. Le linee guida utilizzate dai medici permettono di prendere decisioni informate su come procedere utilizzando questo tipo di valutazioni. \square




FIGURA 2.18. *xkcd* 1236. SEASHELL. Credits: <https://xkcd.com/1236/>

Gli esempi che abbiamo visto ci insegnano a calcolare il termine a denominatore nella formula di Bayes e ci preparano al prossimo teorema.

TEOREMA 2.76 (Formula di Bayes con più eventi). *Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Sia $(B_i)_{i \in \mathbb{N}}$ una partizione di Ω , ovvero una collezione di eventi tali che $B_i \cap B_j = \emptyset$ per $i \neq j$ e $\Omega = \bigcup_{i \in \mathbb{N}} B_i$. Sia A un evento. Allora, per ogni $j \in \mathbb{N}$,*

$$\mathbb{P}(B_j|A) = \frac{\mathbb{P}(A|B_j)\mathbb{P}(B_j)}{\sum_{i \in \mathbb{N}} \mathbb{P}(A|B_i)\mathbb{P}(B_i)}.$$

DIMOSTRAZIONE. Per la formula di Bayes (Teorema 2.72) il Teorema della probabilità totale (Teorema 2.70) si ha che

$$\mathbb{P}(B_j|A) = \frac{\mathbb{P}(A|B_j)\mathbb{P}(B_j)}{\mathbb{P}(A)} = \frac{\mathbb{P}(A|B_j)\mathbb{P}(B_j)}{\sum_{i \in \mathbb{N}} \mathbb{P}(A|B_i)\mathbb{P}(B_i)}.$$

□

ESEMPIO 2.77. È stato chiesto agli studenti e alle studentesse del III anno di Ingegneria Gestionale quale sia il segreto per passare l'esame di Probabilità e Statistica. Le risposte sono state le seguenti:

- primo gruppo: il 50% ha risposto “studiare bene”;
- secondo gruppo: il 40% ha risposto “fortuna”;
- terzo gruppo: il 10% ha risposto “copiare”.

Inoltre:

- $\frac{3}{4}$ del primo gruppo ha superato l'esame al primo appello.
- $\frac{1}{2}$ del secondo gruppo ha superato l'esame al primo appello.

- $\frac{1}{8}$ del terzo gruppo ha superato l'esame al primo appello.

Intervistiamo uno studente scelto a caso. Ci dice che ha superato l'esame al primo appello. Qual è la probabilità che abbia copiato? E la probabilità che abbia studiato bene?

Definiamo lo spazio degli eventi elementari:

$$\Omega = \{(\omega_1, \omega_2) : \omega_1 \in \{g_1, g_2, g_3\}, \omega_2 \in \{1, 0\}\},$$

dove g_1, g_2, g_3 sono i tre gruppi e $1 = \text{"esame superato al primo appello"}$, $0 = \text{"esame non superato al primo appello"}$. Definiamo gli eventi

$$G_1 = \{(g_1, 1), (g_1, 0)\}, \quad G_2 = \{(g_2, 1), (g_2, 0)\}, \quad G_3 = \{(g_3, 1), (g_3, 0)\},$$

$$S = \{(g_1, 1), (g_2, 1), (g_3, 1)\}.$$

Le ipotesi sono:

$$\mathbb{P}(G_1) = 50\%, \quad \mathbb{P}(G_2) = 40\%, \quad \mathbb{P}(G_3) = 10\%,$$

$$\mathbb{P}(S|G_1) = \frac{3}{4}, \quad \mathbb{P}(S|G_2) = \frac{1}{2}, \quad \mathbb{P}(S|G_3) = \frac{1}{8}.$$

Utilizziamo la formula di Bayes per calcolare

$$\mathbb{P}(G_3|S) = \frac{\mathbb{P}(S|G_3)\mathbb{P}(G_3)}{\mathbb{P}(S|G_1)\mathbb{P}(G_1) + \mathbb{P}(S|G_2)\mathbb{P}(G_2) + \mathbb{P}(S|G_3)\mathbb{P}(G_3)}$$

$$= \frac{\frac{1}{8} \cdot 10\%}{\frac{3}{4} \cdot 50\% + \frac{1}{2} \cdot 40\% + \frac{1}{8} \cdot 10\%} \simeq 2.13\%$$

e per calcolare

$$\mathbb{P}(G_1|S) = \frac{\mathbb{P}(S|G_1)\mathbb{P}(G_1)}{\mathbb{P}(S|G_1)\mathbb{P}(G_1) + \mathbb{P}(S|G_2)\mathbb{P}(G_2) + \mathbb{P}(S|G_3)\mathbb{P}(G_3)}$$

$$= \frac{\frac{3}{4} \cdot 50\%}{\frac{3}{4} \cdot 50\% + \frac{1}{2} \cdot 40\% + \frac{1}{8} \cdot 10\%} \simeq 63.83\%.$$

Conviene studiare bene.³ □

► Riguardo a questo argomento, sono consigliati i video di divulgazione del canale 3Blue1Brown di Grant Sanderson ai seguente link:

- https://www.youtube.com/watch?v=HZGCoVF3YvM&t=285s&ab_channel=3Blue1Brown
- https://www.youtube.com/watch?v=lG4VkJPoG3ko&t=998s&ab_channel=3Blue1Brown

ESEMPIO 2.78. (Problema di Monty Hall) In una trasmissione televisiva viene proposto un gioco a premi. Si può scegliere fra tre porte. Dietro una porta c'è un'automobile. Dietro le altre due porte ci sono capre. Il giocatore sceglie una porta. Il conduttore, che sa cosa c'è dietro ogni porta, ne apre una diversa da quella scelta, mostrando una capra, con questo criterio: se il giocatore ha scelto una capra, il presentatore apre la porta con l'altra capra; se il giocatore ha scelto l'automobile, il presentatore apre uniformemente a caso una delle altre due porte. Quindi chiede: "Vuoi cambiare la tua scelta con l'altra porta chiusa?"

³I dati sono stati inventati dal docente per arrivare a questa conclusione.



FIGURA 2.19. Monty Hall (1921-2017).^a È stato un conduttore televisivo statunitense. Il paradosso è ispirato al gioco televisivo “Let’s make a deal” condotto da Monty Hall.

^aFonte dell’immagine: https://commons.wikimedia.org/wiki/File:Monty_hall_abc_tv.jpg

Per comprendere questo esempio, descriviamo lo spazio degli eventi elementari con terne, in cui scriviamo cosa c’è dietro ogni porta (a = auto, c_1 = capra, c_2 = capra):

$$\Omega = \{(a, c_1, c_2), (a, c_2, c_1), (c_1, a, c_2), (c_1, c_2, a), (c_2, a, c_1), (c_2, c_1, a)\}.$$

Lavoriamo nella situazione in cui il giocatore scelta la prima porta. Il ragionamento è lo stesso per le altre due porte. Consideriamo gli eventi

$$A_1 = \text{“l’automobile è dietro la prima porta”} = \{(a, c_1, c_2), (a, c_2, c_1)\},$$

$$A_2 = \text{“l’automobile è dietro la seconda porta”} = \{(c_1, a, c_2), (c_2, a, c_1)\},$$

$$A_3 = \text{“l’automobile è dietro la terza porta”} = \{(c_1, c_2, a), (c_2, c_1, a)\}.$$

Inizialmente

$$\mathbb{P}(A_1) = \mathbb{P}(A_2) = \mathbb{P}(A_3) = \frac{1}{3}.$$

Quindi all’inizio del gioco, il giocatore ha probabilità $\mathbb{P}(A_1) = \frac{1}{3}$ di aver scelto la porta con l’automobile.

Il presentatore, poi, apre una porta. Supponiamo che apra la seconda porta (il ragionamento è lo stesso se il presentatore apre la terza porta). Consideriamo quindi l’evento

$$\begin{aligned} B &= \text{“il presentatore apre la seconda porta”} = \text{“una capra è dietro la seconda porta”} \\ &= \{(a, c_1, c_2), (a, c_2, c_1), (c_1, c_2, a), (c_2, c_1, a)\}. \end{aligned}$$

Per come è impostato il gioco, abbiamo che

$$\mathbb{P}(B|A_1) = \frac{1}{2}, \quad \mathbb{P}(B|A_2) = 0, \quad \mathbb{P}(B|A_3) = 1.$$

Possiamo allora calcolare, utilizzando il teorema della probabilità totale (Teorema 2.70),

$$\begin{aligned}\mathbb{P}(B) &= \mathbb{P}(B|A_1)\mathbb{P}(A_1) + \mathbb{P}(B|A_2)\mathbb{P}(A_2) + \mathbb{P}(B|A_3)\mathbb{P}(A_3) \\ &= \frac{1}{2} \cdot \frac{1}{3} + 0 \cdot \frac{1}{3} + 1 \cdot \frac{1}{3} = \frac{1}{2}.\end{aligned}$$

Grazie a questo, possiamo aggiornare le probabilità di trovare l'automobile nelle porte:

$$\mathbb{P}(A_1|B) = \frac{\mathbb{P}(B|A_1)\mathbb{P}(A_1)}{\mathbb{P}(B)} = \frac{\frac{1}{2} \cdot \frac{1}{3}}{\frac{1}{2}} = \frac{1}{3},$$

$$\mathbb{P}(A_2|B) = \frac{\mathbb{P}(B|A_2)\mathbb{P}(A_2)}{\mathbb{P}(B)} = \frac{0 \cdot \frac{1}{3}}{\frac{1}{2}} = 0,$$

$$\mathbb{P}(A_3|B) = \frac{\mathbb{P}(B|A_3)\mathbb{P}(A_3)}{\mathbb{P}(B)} = \frac{1 \cdot \frac{1}{3}}{\frac{1}{2}} = \frac{2}{3}.$$

Dopo che sono state aggiornate le probabilità, è più probabile che l'automobile sia dietro la terza porta. Conviene cambiare porta. \square

🎮 Link a un gioco online che simula il problema di Monty Hall: https://orlandopoliba.github.io/pages/games/monty_hall/monty_hall.html.




FIGURA 2.20. *xkcd* 1282. MONTY HALL. Credits: <https://xkcd.com/1282/>

2.3.1. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 2.79. Hai derubato il re e sei stato sbattuto in prigione. Il re è magnanimo e invece di farti squartare sul posto, ti permette di fare un piccolo gioco.

Ti vengono date 100 biglie – 50 nere e 50 bianche – e devi metterle in due urne, nel modo che preferisci, purché rispetti le regole del re.

Devi posizionare tutte le biglie e nessuna delle due urne può essere lasciata vuota. Ogni urna verrà scossa in modo che le biglie siano ben mischiate: l'ordine in cui le metti non importa.

Il re seguirà quindi una semplice procedura: sceglierà una delle due urne a caso (è ugualmente probabile che venga scelta una delle due) e da quell'urna estrarrà una biglia a caso. Se è bianca, vivi; se è nera, sarai dato in pasto ai leoni.

Potresti mettere tutte le biglie bianche in un'urna e tutte quelle nere nell'altra, nel qual caso la tua probabilità di sopravvivere è del 50%. Puoi fare di meglio! Se posizioni le biglie nel miglior modo possibile, qual è la tua probabilità di sopravvivenza?

ESERCIZIO 2.80. Hai messo tre monete in un sacchetto: una è una moneta normale, una ha due teste e una ha due croci.

Qualcuno sceglie una moneta in modo uniforme e casuale dal sacchetto e la lancia. Se esce testa, qual è la probabilità che la moneta sia quella normale?

ESERCIZIO 2.81. Due amiche si recano in libreria. È noto che la probabilità che la prima acquisti libri è 0.6, che la seconda acquisti libri è 0.8 e che entrambe acquistino libri è 0.5. Sapendo che all'uscita dalla libreria almeno una ha acquistato libri, determinare la probabilità che la prima abbia acquistato libri.

ESERCIZIO 2.82. La probabilità che uno studente si presenti preparato all'esame di Probabilità e Statistica è del 75%. Inoltre, la probabilità che uno studente superi l'esame se è preparato è del 96%, mentre la probabilità che uno studente sia promosso se non è preparato è del 3%. Si calcoli la probabilità che uno studente che ha superato l'esame sia preparato e la si confronti con la probabilità che uno studente che ha superato l'esame non sia preparato.

ESERCIZIO 2.83. Una coppia ti dice che ha due figli/e. Ti dicono che la più grande è una bambina. Qual è la probabilità che anche l'altra sia una bambina?

ESERCIZIO 2.84. Una coppia ti dice che ha due figli/e. Ti dicono una delle due è una bambina. Qual è la probabilità che anche l'altra sia una bambina? (N.B.: La domanda è diversa da quella di prima, e anche la risposta...)

ESERCIZIO 2.85. Ci sono tre carte A,B,C. A è rossa su entrambi i lati, B è rossa su un lato e bianca sull'altro, C è bianca su entrambi i lati. Scegli a caso una delle tre carte e la poni sul tavolo: il lato visibile è rosso. Qual è la probabilità che anche il lato non visibile sia rosso?

ESERCIZIO 2.86. Un'amica che ha passato con ottimi voti l'esame di Probabilità e Statistica ti propone questo gioco. Scegliete entrambi una delle possibili coppie di esiti di due lanci di moneta: TT, TC, CT, CC . Ad esempio tu scegli TC e lei CT . Ora lanciate tante volte una moneta e annotate gli esiti, finché gli ultimi due lanci non corrispondono a una delle due coppie. Vince il giocatore che aveva scelto la coppia uscita. Ad esempio: tu hai scelto TC e lei CT ; si lancia tante volte la moneta e questa è la sequenza di esiti

$$(C, C, C, C, T);$$

in questo caso ha vinto lei. La tua amica ti dice che puoi scegliere la coppia per primo. Che scegli?

ESERCIZIO 2.87. (Da Settimana Enigmistica 50103.) Il signor Gedeone è un professore di matematica che tiene un corso sul calcolo delle probabilità. Il giorno delle interrogazioni,

per decidere in maniera imparziale se chiamare un ragazzo o una ragazza, adopera una moneta. La lancia più volte sulla cattedra e vede se si verifica prima una sequenza di tre lanci con due teste consecutive seguite da una croce (la si può indicare con TTC) o una sequenza in cui ci sia una croce seguita da due teste consecutive (CTT). Nel primo caso interroga una delle sei ragazze, nel secondo caso invece un ragazzo. Quanti sono, in tutto, i ragazzi? \square

ESERCIZIO 2.88. Due candidati alle elezioni, T e C , competono per la presidenza di un piccolo paese di 5 abitanti (T e C inclusi). Da un sondaggio risulta che:

- T (elettore 1) voterà per sé stesso;
- C (elettore 2) voterà per sé stesso;
- l'elettore 3 voterà per C ;
- gli elettori 4 e 5 discutono di politica e sono ancora indecisi: si sa che, in totale, ciascuno di loro voterà per T con il 40% di probabilità. Ma il voto dell'elettore 4 influenza il voto dell'elettore 5: se l'elettore 4 decide di votare per C , l'elettore 5 farà lo stesso con $\frac{2}{3}$ di probabilità.

Rispondere ai seguenti quesiti, descrivendo lo spazio campione.

- (1) Qual è la probabilità che C vinca le elezioni?
- (2) Qual è la probabilità che C ottenga esattamente il 40% dei voti degli elettori nel paese?
- (3) Sono finite le elezioni. Supponiamo di sapere che l'elettore 5 abbia votato per T , ma di non conoscere ancora il voto dell'elettore 4. Con che probabilità l'elettore 4 ha votato per C ?

\square

Eventi indipendenti. Introduciamo il concetto di indipendenza tra eventi.

Consideriamo due eventi A e B con $\mathbb{P}(B) > 0$. Abbiamo capito il significato di probabilità condizionata. Supponiamo che si verifichi la seguente uguaglianza

$$\mathbb{P}(A|B) = \mathbb{P}(A).$$

Cosa vuol dire? Vuol dire che, anche se sappiamo che si è verificato l'evento B , la probabilità di A è sempre la stessa. Cioè il verificarsi dell'evento B non condiziona la probabilità dell'evento A . Questa è l'indipendenza. Per evitare di richiedere che $\mathbb{P}(B) > 0$, si osserva che

$$\mathbb{P}(A|B) = \mathbb{P}(A) \iff \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} = \mathbb{P}(A) \iff \mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B).$$

DEFINIZIONE 2.89. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Due eventi A e B si dicono *indipendenti* se

$$\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B).$$

\square

ESEMPIO 2.90. (Lancio di due monete) Consideriamo il lancio di due monete. Supponiamo che tutti gli eventi elementari siano equiprobabili. Lo spazio degli eventi elementari




FIGURA 2.21. *xkcd* 2354. BAYES' THEOREM. Credits: <https://xkcd.com/2354/>

è

$$\Omega = \{(T, T), (T, C), (C, T), (C, C)\}.$$

Stiamo assumendo che

$$\mathbb{P}(\{(T, T)\}) = \mathbb{P}(\{(T, C)\}) = \mathbb{P}(\{(C, T)\}) = \mathbb{P}(\{(C, C)\}) = \frac{1}{4}.$$

Consideriamo gli eventi:

$$A_1 = \text{“al primo lancio esce testa”} = \{(T, T), (T, C)\},$$

$$A_2 = \text{“al secondo lancio esce testa”} = \{(T, T), (C, T)\},$$

Osserviamo che

$$\mathbb{P}(A_1 \cap A_2) = \mathbb{P}(\{(T, T)\}) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = \mathbb{P}(A_1)\mathbb{P}(A_2),$$

quindi gli eventi A_1 e A_2 sono indipendenti. L'esito del primo lancio non influenza l'esito del secondo lancio. \square

ESEMPIO 2.91. L'indipendenza tra eventi non gode della proprietà transitiva. Consideriamo come spazio degli eventi elementari Ω un quadrato di lato e definiamo gli eventi A , B , C come in Figura 2.91, utilizzando come misura di probabilità l'area.




FIGURA 2.22. I tre eventi usati nell'Esempio 2.91.

Si ha che

$$\mathbb{P}(A \cap B) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = \mathbb{P}(A)\mathbb{P}(B),$$

ovvero A e B sono indipendenti,

$$\mathbb{P}(B \cap C) = \frac{1}{4} = \frac{1}{2} \cdot \frac{1}{2} = \mathbb{P}(B)\mathbb{P}(C),$$

ovvero B e C sono indipendenti,

$$\mathbb{P}(A \cap C) = 0 \neq \frac{1}{2} \cdot \frac{1}{2} = \mathbb{P}(A)\mathbb{P}(C),$$

ovvero A e C non sono indipendenti. □

ESEMPIO 2.92. (Lancio di tre dadi) Consideriamo l'esito del lancio di tre dadi, assumendo tutti gli eventi elementari equiprobabili. Lo spazio degli eventi elementari è dato da

$$\Omega = \{(\omega_1, \omega_2, \omega_3) : \omega_1, \omega_2, \omega_3 \in \{1, 2, 3, 4, 5, 6\}\}.$$

Osserviamo che

$$\#\Omega = 6^3.$$

Consideriamo gli eventi

$$A = \text{“il primo e il secondo lancio sono uguali”} = \{(\omega_1, \omega_1, \omega_3) : \omega_1, \omega_3 \in \{1, 2, 3, 4, 5, 6\}\},$$

$$B = \text{“il secondo e il terzo lancio sono uguali”} = \{(\omega_1, \omega_2, \omega_2) : \omega_1, \omega_2 \in \{1, 2, 3, 4, 5, 6\}\},$$

$$C = \text{“il primo e il terzo lancio sono uguali”} = \{(\omega_1, \omega_2, \omega_1) : \omega_1, \omega_2 \in \{1, 2, 3, 4, 5, 6\}\}.$$

Osserviamo che

$$\#A = 6^2, \#B = 6^2, \#C = 6^2,$$

quindi

$$\mathbb{P}(A) = \mathbb{P}(B) = \mathbb{P}(C) = \frac{1}{6}.$$

Osserviamo che

$$\begin{aligned} A \cap B &= \text{“il primo e il secondo sono uguali, il secondo e il terzo sono uguali”} \\ &= \text{“i tre esiti sono uguali”} \\ &= \{(\omega_1, \omega_1, \omega_1) : \omega_1 \in \{1, 2, 3, 4, 5, 6\}\}, \end{aligned}$$

$$\begin{aligned}
B \cap C &= \text{“il secondo e il terzo sono uguali, il primo e il terzo sono uguali”} \\
&= \text{“i tre esiti sono uguali”} \\
&= \{(\omega_1, \omega_1, \omega_1) : \omega_1 \in \{1, 2, 3, 4, 5, 6\}\},
\end{aligned}$$

$$\begin{aligned}
A \cap C &= \text{“il primo e il secondo sono uguali, il primo e il terzo sono uguali”} \\
&= \text{“i tre esiti sono uguali”} \\
&= \{(\omega_1, \omega_1, \omega_1) : \omega_1 \in \{1, 2, 3, 4, 5, 6\}\}.
\end{aligned}$$

e

$$\#A \cap B = 6, \#B \cap C = 6, \#A \cap C = 6.$$

Segue che

$$\begin{aligned}
\mathbb{P}(A \cap B) &= \frac{6}{6^3} = \frac{1}{6^2} = \frac{1}{6} \cdot \frac{1}{6} = \mathbb{P}(A)\mathbb{P}(B), \\
\mathbb{P}(B \cap C) &= \frac{6}{6^3} = \frac{1}{6^2} = \frac{1}{6} \cdot \frac{1}{6} = \mathbb{P}(B)\mathbb{P}(C), \\
\mathbb{P}(A \cap C) &= \frac{6}{6^3} = \frac{1}{6^2} = \frac{1}{6} \cdot \frac{1}{6} = \mathbb{P}(A)\mathbb{P}(C).
\end{aligned}$$

Concludiamo che: A e B sono indipendenti; B e C sono indipendenti; A e C sono indipendenti. Possiamo concludere che i tre eventi sono tra loro indipendenti? Quello che abbiamo controllato non basta. Ad esempio, il verificarsi di entrambi A e B influenza la probabilità di C ! Infatti se si verificano A e B , si deve verificare anche C , cioè $A \cap B \subset C$, quindi

$$\mathbb{P}((A \cap B) \cap C) = \mathbb{P}(A \cap B) = \frac{1}{6^2} \neq \mathbb{P}(A \cap B)\mathbb{P}(C).$$

□

ESERCIZIO 2.93. Si consideri il lancio di due dadi. Si definiscono i seguenti eventi:

$$A = \text{“l'esito del secondo lancio è 1 oppure 2 oppure 5”},$$

$$B = \text{“l'esito del secondo lancio è 4 oppure 5 oppure 6”},$$

$$C = \text{“la somma dei risultati è 9”}.$$

Mostrare che

$$\mathbb{P}(A \cap B \cap C) = \mathbb{P}(A)\mathbb{P}(B)\mathbb{P}(C),$$

tuttavia

$$\mathbb{P}(A \cap B) \neq \mathbb{P}(A)\mathbb{P}(B), \mathbb{P}(A \cap B) \neq \mathbb{P}(A)\mathbb{P}(B), \mathbb{P}(A \cap C) \neq \mathbb{P}(A)\mathbb{P}(C).$$

□

Gli esempi precedenti motivano la seguente definizione.

DEFINIZIONE 2.94. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Siano A_1, \dots, A_n eventi. Gli eventi A_1, \dots, A_n si dicono *indipendenti* se

$$\mathbb{P}\left(\bigcap_{j \in J} A_j\right) = \prod_{j \in J} \mathbb{P}(A_j)$$

per ogni sottoinsieme $J \subset \{1, \dots, n\}$.

□

2.3.2. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 2.95. Per incoraggiare la carriera di tennis del figlio, un genitore gli offre un premio se vince almeno due set consecutivi in un match da 3 set, da giocare alternatamente contro il padre o contro il campione di tennis del circolo. Può quindi scegliere tra

padre-campione-padre
campione-padre-campione

Il campione è ovviamente il giocatore migliore tra i due (la probabilità di vittoria contro il padre è maggiore di quella di vittoria contro il campione). Quale serie conviene giocare? (Si assuma vittorie o sconfitte nei vari match siano indipendenti.) \square

ESERCIZIO 2.96. Una giuria di 3 membri è composta da:

- 2 giudici, ciascuno dei quali ha (indipendentemente) probabilità p di prendere la decisione giusta;
- 1 giudice che lancia una moneta per prendere la decisione.

Il giudizio è espresso a maggioranza. Una seconda giuria è composta da un solo membro che ha probabilità p di prendere la decisione giusta. Quale delle due giurie ha maggiore probabilità di prendere la decisione giusta? \square

ESERCIZIO 2.97. Alice e Bob fanno un gioco. A turni lanciano un dado. Il primo che ottiene un 6 vince. Se Alice inizia, qual è la probabilità che vinca? \square

ESERCIZIO 2.98. Alice e Bob sono a cena e hanno a disposizione una moneta (con facce “testa” e “croce”) per decidere chi deve pagare il conto. Alice non sa però se la moneta è bilanciata. Ma è onesta e propone a Bob un gioco equo, con cui i due hanno la stessa probabilità di vincere. Il gioco è basato sulla scommessa sull'esito di due lanci consecutivi della moneta. Che gioco propone? \square

ESERCIZIO 2.99. Consideriamo una moneta che è truccata con il 50% di probabilità. Se è truccata, esce sempre testa.

- (1) Osserviamo l'esito di un lancio: esce testa. Conoscendo questo esito, con che probabilità la moneta è effettivamente truccata?
- (2) Osserviamo l'esito di 3 lanci consecutivi indipendenti: esce testa in tutti e 3 i lanci. Conoscendo questo esito, con che probabilità la moneta è effettivamente truccata?

\square

CAPITOLO 3

Variabili aleatorie

Contenuti

3.1. Variabili aleatorie	79
Definizione e primi esempi	79
Legge di una variabile aleatoria	82
3.2. Variabili aleatorie discrete	84
3.3. Vettori aleatori	85
3.4. Vettori aleatori discreti con due componenti	87
3.5. Valore atteso per variabili aleatorie discrete	89
3.6. Variabili aleatorie assolutamente continue	91
3.7. Vettori aleatori assolutamente continui con due componenti	93
3.8. Valore atteso per variabili aleatorie assolutamente continue	96
3.9. Varianza, deviazione standard e covarianza per variabili aleatorie discrete	101
3.9.1. Esercizi	105

3.1. Variabili aleatorie

Definizione e primi esempi. In questo capitolo introduciamo il concetto di variabile aleatoria. Saranno lo strumento che utilizzeremo d'ora in poi per descrivere gli eventi casuali. Vengono chiamate “variabili” perché finché non viene osservato l'esito dell'esperimento casuale non è possibile conoscerne il valore assunto.

Per comprendere in che senso le variabili aleatorie descrivono eventi casuali, partiamo con un esempio.

ESEMPIO 3.1. (Tiro a bersaglio) Torniamo all'esempio del tiro a bersaglio considerato nel capitolo precedente. Lo spazio degli eventi elementari è

$$\Omega = \{\omega \in \mathbb{R}^2 \text{ tale che } |\omega| \leq r\}.$$

La collezione di eventi \mathcal{F} costituita dai sottoinsiemi Boreliani di \mathbb{R}^2 contenuti in Ω . Per ogni $A \in \mathcal{F}$ si può calcolare l'area $|A|$. Si definisce la misura di probabilità

$$\mathbb{P}(A) := \frac{1}{\pi r^2} |A|.$$

Nel tiro a bersaglio vengono contati dei punti a seconda di dove finisce la freccetta. Consideriamo una funzione X che descriva i punteggi. Si veda la Figura 3.1.

$$X(\omega) = \text{“punteggi”} = \begin{cases} 100, & \text{se } |\omega| < r_1, \\ 50, & \text{se } r_1 \leq |\omega| < r_2, \\ 20, & \text{se } r_2 \leq |\omega| < r_3, \\ 10, & \text{se } r_3 \leq |\omega| < r. \end{cases}$$




FIGURA 3.1. Tiro a bersaglio.

Possiamo descrivere alcuni eventi utilizzando la funzione X . Ovvero

$$\text{“100 punti”} = \{\omega \in \Omega : |\omega| < r_1\} = \{\omega \in \Omega : X(\omega) = 100\} = \{X = 100\},$$

$$\text{“50 punti”} = \{\omega \in \Omega : r_1 \leq |\omega| < r_2\} = \{\omega \in \Omega : X(\omega) = 50\} = \{X = 50\},$$

$$\text{“20 punti”} = \{\omega \in \Omega : r_2 \leq |\omega| < r_3\} = \{\omega \in \Omega : X(\omega) = 20\} = \{X = 20\},$$

$$\text{“10 punti”} = \{\omega \in \Omega : r_3 \leq |\omega| < r\} = \{\omega \in \Omega : X(\omega) = 10\} = \{X = 10\}.$$

Possiamo calcolare, ad esempio,

$$\mathbb{P}(\{X = 50\}) = \frac{1}{\pi r^2} (r_2^2 - r_1^2).$$

□

Nello spirito dell'esempio precedente, forniamo la seguente definizione. Per una funzione $X: \Omega \rightarrow \mathbb{R}$ utilizzeremo la notazione breve

$$\{X \in I\} = \{\omega \in \Omega \text{ tale che } X(\omega) \in I\}.$$

DEFINIZIONE 3.2. (Variabile aleatoria) Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Una *variabile aleatoria* (o *variabile casuale* o *variabile random* o *variabile stocastica*) è una funzione $X: \Omega \rightarrow \mathbb{R}$ tale che $\{X \in I\} \in \mathcal{F}$ (ovvero, $\{X \in I\}$ è un evento) per ogni intervallo $I \subset \mathbb{R}$.¹ □

¹Per “intervallo” si intende uno dei seguenti insiemi: (a, b) , $[a, b]$, $[a, b)$, $(a, b]$, $(a, +\infty)$, $[a, +\infty)$, $(-\infty, b)$, $(-\infty, b]$.

OSSERVAZIONE 3.3. \blacktriangle Se lo spazio di probabilità è finito, la condizione $\{X \in I\} \in \mathcal{F}$ è banalmente verificata perché \mathcal{F} è la collezione di tutti i sottoinsiemi di Ω . La condizione $\{X \in I\} \in \mathcal{F}$ serve quando lo spazio di probabilità è infinito e \mathcal{F} non è costituita dalla collezione di tutti i sottoinsiemi. Non ci preoccuperemo di questo dettaglio tecnico in questo corso: le variabili aleatorie che presenteremo verificano tutte la condizione. \square

ESEMPIO 3.4. Lanciamo due dadi. Lo spazio degli eventi elementari è

$$\Omega = \{(\omega_1, \omega_2) : \omega_i \in 1, 2, 3, 4, 5, 6\}.$$

Consideriamo la variabile aleatoria che fornisce la somma degli esiti

$$X(\omega_1, \omega_2) = \omega_1 + \omega_2.$$

La probabilità che la somma degli esiti sia 7 è $\mathbb{P}(\{X = 7\})$. Possiamo calcolarla:

$$\{X = 7\} = \{(1, 6), (2, 5), (3, 4), (4, 3), (5, 2), (6, 1)\}$$

quindi

$$\mathbb{P}(\{X = 7\}) = \frac{6}{6^2} = \frac{1}{6}.$$

Possiamo calcolare

$$\mathbb{P}(\{X = 12\}) = \frac{1}{6^2} = \frac{1}{36}.$$

\square

ESEMPIO 3.5. Si lancia un dado tante volte consecutive in modo indipendente. Lo spazio degli eventi elementari è

$$\Omega = \{(\omega_1, \omega_2, \dots, \omega_n, \dots) : \omega_i \in \{1, 2, 3, 4, 5, 6\}\}.$$

Consideriamo la variabile aleatoria

$$X(\omega_1, \omega_2, \dots) = i,$$

se $\omega_i = 6$ e $\omega_j \neq 6$ per $j \leq i$. Questa variabile aleatoria descrive la prima volta in cui viene osservato l'esito 6 nella sequenza di lanci. \square

DEFINIZIONE 3.6. Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria. Il *range* della variabile aleatoria è l'insieme dei valori che possono essere assunti dalla variabile aleatoria

$$R(X) = \{X(\omega) : \omega \in \Omega\}.$$

Una variabile aleatoria è *discreta* se il suo range è un insieme finito o numerabile. Una variabile aleatoria è *continua* se il suo range è un intervallo (o un'unione di intervalli). \square

OSSERVAZIONE 3.7. Se $I \cap R(X) = \emptyset$ allora $\mathbb{P}(\{X \in I\}) = \mathbb{P}(\emptyset) = 0$. \square

ESEMPIO 3.8. Se una variabile aleatoria X rappresenta la somma del lancio di due dadi, il suo range è $R(X) = \{2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$. \square

ESEMPIO 3.9. Se una variabile aleatoria X rappresenta la vita di un dispositivo, il suo range è $R(X) = [0, +\infty)$. \square

Legge di una variabile aleatoria. Ciò che contraddistingue le variabili aleatorie è la loro *legge* o *distribuzione*. In pratica, la legge di una variabile aleatoria esprime il modo in cui la variabile aleatoria genera numeri casuali. Ogni variabile aleatoria ha una sua legge.

OSSERVAZIONE 3.10. Consideriamo uno spazio di probabilità $(\Omega, \mathcal{F}, \mathbb{P})$ e una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$. È possibile definire, grazie a X , una nuova misura di probabilità sugli eventi di \mathbb{R} (più precisamente sugli insiemi Boreliani). Per definirla, è sufficiente spiegare come opera sugli intervalli. Per ogni intervallo $I \subset \mathbb{R}$ si definisce

$$\mathbb{P}_X(I) = \mathbb{P}(\{X \in I\}).$$

♣ Come accennato nell'Osservazione 2.22, gli insiemi Boreliani hanno buone proprietà e sono fatti in modo che \mathbb{P}_X possa essere estesa dagli intervalli a tutti gli insiemi Boreliani. Si può dimostrare che \mathbb{P}_X è una misura di probabilità su \mathbb{R} . \square

DEFINIZIONE 3.11. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità e sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria. La *legge* o *distribuzione* di X è la misura di probabilità \mathbb{P}_X su \mathbb{R} che sugli intervalli è definita da

$$\mathbb{P}_X(I) = \mathbb{P}(\{X \in I\}).$$

\square

La legge caratterizza le variabili aleatorie. Se sappiamo descrivere una variabile aleatoria con una certa legge, allora sappiamo descrivere tutte le variabili aleatorie con la stessa legge. Per questo motivo si fornisce la seguente definizione.

DEFINIZIONE 3.12. Siano $(\Omega, \mathcal{F}, \mathbb{P})$ e $(\Omega', \mathcal{F}', \mathbb{P}')$ due spazi di probabilità (eventualmente lo stesso) e $X: \Omega \rightarrow \mathbb{R}$ e $Y: \Omega' \rightarrow \mathbb{R}$ due variabili aleatorie. Le variabili aleatorie si dicono *identicamente distribuite* se hanno la stessa legge, ovvero $\mathbb{P}_X = \mathbb{P}_Y$. \square

OSSERVAZIONE 3.13. Se X e Y sono identicamente distribuite, gli eventi generati da X e Y hanno le stesse probabilità, infatti

$$\mathbb{P}(\{X \in I\}) = \mathbb{P}_X(I) = \mathbb{P}_Y(I) = \mathbb{P}(\{Y \in I\}).$$

Per questo motivo il resto del corso si concentrerà sullo studio di alcune leggi. \square

⚠ Una delle difficoltà maggiori dei problemi di probabilità è individuare qual è la legge giusta da utilizzare per modellare un fenomeno casuale. Una volta che la legge è nota, la matematica diventa piuttosto semplice.

ESEMPIO 3.14. Consideriamo il lancio di un dado. Lo spazio degli eventi elementari è

$$\Omega = \{1, 2, 3, 4, 5, 6\}.$$

Consideriamo la variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$

$$X(\omega) = \begin{cases} 1 & \text{se } \omega \in \{1, 3, 5\}, \\ 0 & \text{se } \omega \in \{2, 4, 6\}. \end{cases}$$

Consideriamo il lancio di una moneta. Lo spazio degli eventi elementari è

$$\Omega' = \{T, C\}.$$

Consideriamo la variabile aleatoria

$$Y(\omega') = \begin{cases} 1 & \text{se } \omega' = T, \\ 0 & \text{se } \omega' = C. \end{cases}$$

Gli esperimenti sono evidentemente diversi. Tuttavia le variabili aleatorie X e Y sono identicamente distribuite, infatti

$$\mathbb{P}(\{X = 1\}) = \frac{1}{2} = \mathbb{P}(\{Y = 1\}), \quad \mathbb{P}(\{X = 0\}) = \frac{1}{2} = \mathbb{P}(\{Y = 0\}).$$

Quindi è equivalente studiare i fenomeni descritti da X e quelli descritti da Y . \square

Un ulteriore strumento utilizzato per descrivere la legge di una variabile aleatoria è la funzione di distribuzione cumulativa.

DEFINIZIONE 3.15. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria. La *funzione di distribuzione cumulativa* (FDC) di X è la funzione $F_X: \mathbb{R} \rightarrow [0, 1]$ definita da

$$F_X(x) := \mathbb{P}(\{X \leq x\}).$$

\square

OSSERVAZIONE 3.16. La funzione di distribuzione cumulativa è una funzione crescente in x e verifica

$$\lim_{x \rightarrow -\infty} F_X(x) = 0, \quad \lim_{x \rightarrow +\infty} F_X(x) = 1.$$

\square

OSSERVAZIONE 3.17. L'importanza della funzione di distribuzione cumulativa è dovuta al fatto che permette di ricostruire completamente la legge della variabile aleatoria. Infatti

$$\begin{aligned} \mathbb{P}_X((a, b]) &= \mathbb{P}(\{X \in (a, b]\}) = \mathbb{P}(\{a < X \leq b\}) = \mathbb{P}(\{X \leq b\} \setminus \{X \leq a\}) \\ &= \mathbb{P}(\{X \leq b\}) - \mathbb{P}(\{X \leq a\}) = F_X(b) - F_X(a). \end{aligned}$$

Da questa relazione possiamo ricavare come opera la legge su tutti gli intervalli. Ad esempio:

$$\mathbb{P}_X((a, b)) = \lim_{b' \rightarrow b} \mathbb{P}_X((a, b']) = \lim_{b' \rightarrow b} (F_X(b') - F_X(a)).$$

Oppure

$$\mathbb{P}_X((a, +\infty)) = \lim_{b \rightarrow +\infty} \mathbb{P}_X((a, b]) = \lim_{b \rightarrow +\infty} (F_X(b) - F_X(a)) = 1 - F_X(a).$$

\square

Faremo esempi espliciti di funzioni di distribuzioni cumulative per le leggi che studieremo.

Concludiamo questa sezione fornendo la definizione di variabili aleatorie indipendenti.

DEFINIZIONE 3.18. (Variabili aleatorie indipendenti) Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Siano $X_1, \dots, X_n: \Omega \rightarrow \mathbb{R}$ variabili aleatorie. Le variabili aleatorie si dicono indipendenti se

$$\mathbb{P}\left(\bigcap_{i=1}^n \{X_i \in I_i\}\right) = \prod_{i=1}^n \mathbb{P}(\{X_i \in I_i\})$$

per ogni $I_1, \dots, I_n \subset \mathbb{R}$ intervalli. \square

OSSERVAZIONE 3.19. La definizione di indipendenza di variabili aleatorie richiede che tutti gli eventi che possono essere generati dalle variabili aleatorie sono indipendenti. Potrebbe sembrare leggermente differente dalla definizione di indipendenza di n eventi, ma attenzione: qui è richiesto che la condizione sia vera comunque siano scelti gli intervalli $I_1, \dots, I_n \subset \mathbb{R}$. Questo permette di scegliere come intervalli anche l'intero \mathbb{R} . \square

Spesso considereremo nel corso variabili aleatorie X_1, \dots, X_n indipendenti e identicamente distribuite. Per scrivere in breve diremo che X_1, \dots, X_n sono i.i.d.

3.2. Variabili aleatorie discrete

Consideriamo in questa sezione variabili aleatorie discrete.

Data $X: \Omega \rightarrow \mathbb{R}$ con range $R(X) = \{x_1, \dots, x_n, \dots\}$, la sua legge è completamente identificata dalla probabilità degli eventi del tipo $\{X = x_i\}$. Come abbiamo osservato in precedenza, la probabilità che vengano assunti valori fuori dal range è zero.

DEFINIZIONE 3.20. Data una variabile aleatoria discreta $X: \Omega \rightarrow \mathbb{R}$ con range $R(X) = \{x_1, \dots, x_n, \dots\}$, la funzione

$$x \in R(X) \mapsto \mathbb{P}(\{X = x\}) \in [0, 1]$$

è detta *funzione di massa di probabilità*. \square

OSSERVAZIONE 3.21. Osserviamo che

$$\sum_{x \in R(X)} \mathbb{P}(\{X = x\}) = 1.$$

\square

OSSERVAZIONE 3.22. Siano x_1, \dots, x_n, \dots con $x_i \in \mathbb{R}$ e p_1, \dots, p_n, \dots tali che $p_i \in [0, 1]$ e $\sum_{i=1}^{\infty} p_i = 1$. Allora esiste una variabile aleatoria X con funzione di massa di probabilità determinata da

$$\mathbb{P}(\{X = x_i\}) = p_i.$$

Infatti è sufficiente considerare lo spazio di probabilità $\Omega = \{x_1, \dots, x_n, \dots\}$ con misura di probabilità data da

$$\mathbb{P}(\{x_i\}) = p_i.$$

È sufficiente definire la variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ data da $X(\omega) = \omega$. \square

OSSERVAZIONE 3.23. Possiamo rappresentare la funzione di massa di probabilità in un grafico come in Figura 3.2. Capiremo con gli esempi che la rappresentazione della funzione di massa di probabilità è il tipico diagramma a barre delle frequenze relative per dati di campioni estratti dalla variabile aleatoria.




FIGURA 3.2. Rappresentazione della funzione di massa di probabilità di una variabile aleatoria discreta.

□

3.3. Vettori aleatori

DEFINIZIONE 3.24. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Un *vettore aleatorio* è una funzione $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ tale che X_1, \dots, X_n sono variabili aleatorie. □

DEFINIZIONE 3.25. La *legge congiunta* di un vettore aleatorio $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ è la misura di probabilità definita da

$$\mathbb{P}_X(E) = \mathbb{P}(\{X \in E\}),$$

per ogni $E \subset \mathbb{R}^n$ (Boreliano). Le leggi $\mathbb{P}_{X_1}, \dots, \mathbb{P}_{X_n}$ delle componenti X_1, \dots, X_n sono dette *leggi marginali*. □

OSSERVAZIONE 3.26. Se X_1, \dots, X_n sono indipendenti, allora è possibile ricostruire la legge congiunta dalle leggi marginali. Infatti, dati $I_1, \dots, I_n \subset \mathbb{R}$ intervalli si ha che

$$\begin{aligned} \mathbb{P}_X(I_1 \times \dots \times I_n) &= \mathbb{P}(\{X \in I_1 \times \dots \times I_n\}) \\ &= \mathbb{P}(\{X_1 \in I_1\} \cap \dots \cap \{X_n \in I_n\}) \\ &= \mathbb{P}(\{X_1 \in I_1\}) \cdots \mathbb{P}(\{X_n \in I_n\}) = \mathbb{P}_{X_1}(I_1) \cdots \mathbb{P}_{X_n}(I_n). \end{aligned}$$

È poi possibile ricostruire \mathbb{P}_X su ogni insieme $E \subset \mathbb{R}^n$ Boreliano a partire dal suo valore sugli insiemi della forma $I_1 \times \dots \times I_n$ □

DEFINIZIONE 3.27. Siano $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ e $Y = (Y_1, \dots, Y_m): \Omega \rightarrow \mathbb{R}^m$ due vettori aleatori. I vettori aleatori X e Y si dicono *indipendenti* se

$$\mathbb{P}(\{X \in E\} \cap \{Y \in F\}) = \mathbb{P}(\{X \in E\})\mathbb{P}(\{Y \in F\})$$

per ogni $E \subset \mathbb{R}^n$ e $F \subset \mathbb{R}^m$ (Boreliani). \square

PROPOSIZIONE 3.28. *Siano $X_1, \dots, X_n, Y_1, \dots, Y_m: \Omega \rightarrow \mathbb{R}$ variabili aleatorie. Siano $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ e $Y = (Y_1, \dots, Y_m): \Omega \rightarrow \mathbb{R}^m$. Se $X_1, \dots, X_n, Y_1, \dots, Y_m$ sono indipendenti, allora X e Y sono indipendenti.*

DIMOSTRAZIONE. È sufficiente dimostrare il risultato per $E = I_1 \times \dots \times I_n$ e $F = J_1 \times \dots \times J_m$.² Consideriamo $I_1, \dots, I_n, J_1, \dots, J_m \subset \mathbb{R}$ intervalli. Se $X_1, \dots, X_n, Y_1, \dots, Y_m$ sono indipendenti si ha che

$$\begin{aligned} & \mathbb{P}(\{X \in I_1 \times \dots \times I_n\} \cap \{Y \in J_1 \times \dots \times J_m\}) \\ &= \mathbb{P}(\{X_1 \in I_1\} \cap \dots \cap \{X_n \in I_n\} \cap \{Y_1 \in J_1\} \cap \dots \cap \{Y_m \in J_m\}) \\ &= \mathbb{P}(\{X_1 \in I_1\}) \cdots \mathbb{P}(\{X_n \in I_n\}) \mathbb{P}(\{Y_1 \in J_1\}) \cdots \mathbb{P}(\{Y_m \in J_m\}) \\ &= \mathbb{P}(\{X_1 \in I_1\} \cap \dots \cap \{X_n \in I_n\}) \mathbb{P}(\{Y_1 \in J_1\} \cap \dots \cap \{Y_m \in J_m\}). \end{aligned}$$

\square

Consideriamo un vettore aleatorio $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ e una funzione $H: \mathbb{R}^n \rightarrow \mathbb{R}$. Sotto opportune condizioni³ su H , si ha che $H(X_1, \dots, X_n)$ è una variabile aleatoria, ovvero $\{H(X) \in I\}$ è un evento per ogni intervallo $I \subset \mathbb{R}$. Si può mostrare che questo è vero sicuramente quando H è una funzione continua. Tutti i casi che considereremo in questo corso sono tali che $H(X_1, \dots, X_n)$ è una variabile aleatoria.

PROPOSIZIONE 3.29. *Siano $X = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ e $Y = (Y_1, \dots, Y_m): \Omega \rightarrow \mathbb{R}^m$ due vettori aleatori. Siano $H: \mathbb{R}^n \rightarrow \mathbb{R}$ e $G: \mathbb{R}^m \rightarrow \mathbb{R}$ due funzioni tali che $H(X_1, \dots, X_n)$ e $G(Y_1, \dots, Y_m)$ siano variabili aleatorie. Se $X = (X_1, \dots, X_n)$ e $Y = (Y_1, \dots, Y_m)$ sono indipendenti, allora $H(X_1, \dots, X_n)$ e $G(Y_1, \dots, Y_m)$ sono variabili aleatorie indipendenti.*

DIMOSTRAZIONE. Consideriamo due intervalli $I, J \subset \mathbb{R}$. Consideriamo l'insieme

$$H^{-1}(I) = \{x \in \mathbb{R}^n \text{ tale che } H(x) \in I\}.$$

Allora

$$H(X(\omega)) \in I \iff X(\omega) \in H^{-1}(I).$$

Facendo lo stesso discorso su Y abbiamo che

$$\begin{aligned} \mathbb{P}(\{H(X) \in I\} \cap \{G(Y) \in J\}) &= \mathbb{P}(\{X \in H^{-1}(I)\} \cap \{Y \in G^{-1}(J)\}) \\ &= \mathbb{P}(\{X \in H^{-1}(I)\}) \mathbb{P}(\{Y \in G^{-1}(J)\}) \\ &= \mathbb{P}(\{H(X) \in I\}) \mathbb{P}(\{G(Y) \in J\}). \end{aligned}$$

\square

ESEMPIO 3.30. Date X_1, \dots, X_n variabili aleatorie, e considerando la funzione definita da $H(x_1, \dots, x_n) := x_1 + \dots + x_n$ otteniamo che $H(X_1, \dots, X_n) = X_1 + \dots + X_n$ è una variabile aleatoria. \square

²Questo è un fatto delicato.

³Questa precisazione non è necessaria quando X_1, \dots, X_n sono variabili aleatorie discrete finite.

OSSERVAZIONE 3.31. Combinando la Proposizione 3.28 e la Proposizione 3.29 otteniamo il seguente fatto: se $X_1, \dots, X_n, Y_1, \dots, Y_m: \Omega \rightarrow \mathbb{R}$ sono variabili aleatorie indipendenti, allora $X_1 + \dots + X_n$ e $Y_1 + \dots + Y_m$ sono variabili aleatorie indipendenti. \square

3.4. Vettori aleatori discreti con due componenti

Studiamo in questa sezione più in dettaglio vettori aleatori discreti con due componenti, ovvero della forma (X, Y) dove X e Y sono variabili aleatorie discrete.

Per questi vettori aleatori, la legge congiunta può essere rappresentata in una tabella. Siano $R(X) = \{x_1, \dots, x_m\}$ e $R(Y) = \{y_1, \dots, y_n\}$ i range di X e Y , rispettivamente e sia

$$p_{ij} = \mathbb{P}(\{X = x_i\} \cap \{Y = y_j\})$$

per $i = 1, \dots, m$ e $j = 1, \dots, n$. Riassumiamo queste notazioni nella seguente tabella:

	X	x_1	x_2	\cdots	x_m
Y					
y_1		p_{11}	p_{21}	\cdots	p_{m1}
y_2		p_{12}	p_{22}	\cdots	p_{m2}
\vdots		\vdots	\vdots	\ddots	\vdots
y_m		p_{1n}	p_{2n}	\cdots	p_{mn}

OSSERVAZIONE 3.32. Le entrate della tabella devono verificare la condizione necessaria

$$\sum_{i=1}^m \sum_{j=1}^n p_{ij} = 1.$$

\square

Studiamo come calcolare le leggi marginali.

PROPOSIZIONE 3.33. *Siano X, Y due variabili aleatorie discrete. Allora, per ogni $x \in R(X)$ e $y \in R(Y)$ si ha che*

$$\mathbb{P}(\{X = x\}) = \sum_{y \in R(Y)} \mathbb{P}(\{X = x, Y = y\}),$$

$$\mathbb{P}(\{Y = y\}) = \sum_{x \in R(X)} \mathbb{P}(\{X = x, Y = y\}).$$

DIMOSTRAZIONE. Le formule seguono semplicemente dal fatto che

$$\{X = x\} = \bigcup_{y \in R(Y)} \{X = x, Y = y\},$$

$$\{Y = y\} = \bigcup_{x \in R(X)} \{X = x, Y = y\},$$

e le unioni sono disgiunte. \square

Applicando la proposizione precedente alla tabella che riassume la legge congiunta del vettore aleatorio, deduciamo che la legge marginale di X si ottiene sommando sulle colonne della tabella, mentre la legge marginale di Y si ottiene sommando sulle righe della tabella. Più precisamente:

$$\mathbb{P}(\{X = x_i\}) = \sum_{j=1}^n p_{ij}, \quad \mathbb{P}(\{Y = y_j\}) = \sum_{i=1}^m p_{ij}.$$

OSSERVAZIONE 3.34. Se (X, Y) è un vettore aleatorio discreto e X e Y sono indipendenti, allora è possibile ricostruire la legge congiunta di (X, Y) semplicemente a partire dalle leggi marginali X e Y . Infatti

$$\mathbb{P}(\{X = x_i\} \cap \{Y = y_j\}) = \mathbb{P}(\{X = x_i\})\mathbb{P}(\{Y = y_j\})$$

grazie all'indipendenza. Al contrario, se X e Y sono dipendenti, occorre avere altre informazioni per ricostruire la legge congiunta, come ad esempio le probabilità di X condizionate dai valori di Y o viceversa. Mostriamo questo concetto nei prossimi due esempi. \square

ESEMPIO 3.35. (Due estrazioni con reimmissione) Consideriamo un'urna con n palline numerate da 1 a n . Estraiamo dall'urna due palline con reimmissione e in modo indipendente. Consideriamo le variabili aleatorie

$$X = \text{"primo numero estratto"}, \quad Y = \text{"secondo numero estratto"}.$$

Calcoliamo la legge congiunta di (X, Y) e le leggi marginali di X e di Y .

$$\mathbb{P}(\{X = i\}) = \frac{1}{n}, \quad \mathbb{P}(\{Y = j\}) = \frac{1}{n}$$

e per l'indipendenza

$$\mathbb{P}(\{X = i\} \cap \{Y = j\}) = \mathbb{P}(\{X = i\})\mathbb{P}(\{Y = j\}) = \frac{1}{n^2}.$$

\square

ESEMPIO 3.36. (Due estrazioni senza reimmissione) Consideriamo un'urna con n palline numerate da 1 a n . Estraiamo dall'urna due palline senza reimmissione (le estrazioni sono quindi dipendenti!). Consideriamo le variabili aleatorie

$$X = \text{"primo numero estratto"}, \quad Y = \text{"secondo numero estratto"}.$$

Calcoliamo la legge congiunta di (X, Y) e le leggi marginali di X e di Y .

Per la variabile aleatoria X abbiamo che

$$\mathbb{P}(\{X = i\}) = \frac{1}{n}.$$

Per la variabile aleatoria Y , invece,

$$\mathbb{P}(\{Y = j\}|\{X = i\}) = \begin{cases} \frac{1}{n-1}, & \text{se } i \neq j, \\ 0, & \text{se } i = j. \end{cases}$$

Possiamo calcolare la legge congiunta utilizzando la definizione di probabilità condizionata:

$$\mathbb{P}(\{X = i\} \cap \{Y = j\}) = \mathbb{P}(\{Y = j\} | \{X = i\}) \mathbb{P}(\{X = i\}) = \begin{cases} \frac{1}{n} \frac{1}{n-1}, & \text{se } i \neq j, \\ 0, & \text{se } i = j. \end{cases}$$

Quindi la legge congiunta è diversa da quella dell'Esempio 3.35.

Calcoliamo le leggi marginali. Per la legge marginale della variabile aleatoria X abbiamo che è la stessa dell'Esempio 3.35. Per la Y utilizziamo il Teorema della Probabilità Totale per stabilire che

$$\mathbb{P}(\{Y = j\}) = \sum_{i=1}^n \mathbb{P}(\{Y = j\} | \{X = i\}) \mathbb{P}(\{X = i\}) = \sum_{\substack{i=1 \\ i \neq j}}^n \frac{1}{n-1} \frac{1}{n} = \frac{1}{n}.$$

Quindi Y ha la stessa legge marginale dell'Esempio 3.35. Questi esempi mostrano che le leggi marginali non sono sufficienti a identificare la legge congiunta del vettore aleatorio. Per costruire la legge congiunta nel secondo esempio abbiamo sfruttato le informazioni su come una variabile aleatoria modifica le probabilità degli eventi dell'altra. \square

3.5. Valore atteso per variabili aleatorie discrete

L'Osservazione 3.23 ci porta a definire il valore medio tipico di una variabile aleatoria discreta.

DEFINIZIONE 3.37. Sia $(\Omega, \mathcal{F}, \mathbb{P})$ uno spazio di probabilità. Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria discreta. Il *valore atteso* (o *aspettazione* o *speranza matematica*) della variabile aleatoria X è il numero, se ben definito,⁴

$$\mathbb{E}(X) := \sum_{x \in R(X)} x \mathbb{P}(\{X = x\}).$$

\square

Possiamo calcolare il valore atteso di una funzione di un vettore aleatorio. È sufficiente pesare i valori assunti da $H(X_1, \dots, X_n)$ con le probabilità che vengano assunti i valori dalla variabile aleatoria X .

PROPOSIZIONE 3.38 (LOTUS - Law Of The Unconscious Statistician). *Consideriamo $X_1, \dots, X_n: \Omega \rightarrow \mathbb{R}$ variabili aleatorie discrete, e $H: \mathbb{R}^n \rightarrow \mathbb{R}$ una funzione tale che $H(X_1, \dots, X_n)$ sia una variabile aleatoria. Allora il valore atteso di $H(X_1, \dots, X_n)$ è, se ben definito,⁵*

$$\mathbb{E}(H(X_1, \dots, X_n)) = \sum_{(x_1, \dots, x_n) \in R(X_1, \dots, X_n)} H(x_1, \dots, x_n) \mathbb{P}(\{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}).$$

⁴Questa precisazione non occorre nel caso in cui il range $R(X)$ è finito. Se invece $R(X)$ è numerabile, la definizione di $\mathbb{E}(X)$ è scritta in termini di una serie numerica. Per “ben definito” si intende che la serie converge assolutamente, ovvero $\sum_{x \in R(X)} |x| \mathbb{P}(\{X = x\}) < +\infty$.

⁵Questa richiesta ha senso quando il range non è finito e il valore atteso è una serie numerica. Per “ben definito” si intende che la serie è assolutamente convergente, ovvero $\sum_{x \in R(X)} |H(x)| \mathbb{P}(\{X = x\}) < +\infty$.

DIMOSTRAZIONE. Il range di $H(X_1, \dots, X_n)$ è dato da

$$\begin{aligned} R(H(X_1, \dots, X_n)) \\ = \{y \in \mathbb{R} \text{ tale che } H(x_1, \dots, x_n) = y \text{ per qualche } (x_1, \dots, x_n) \in R(X_1, \dots, X_n)\}. \end{aligned}$$

Osserviamo che

$$\{H(X_1, \dots, X_n) = y\} = \bigcup_{\substack{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) \\ H(x_1, \dots, x_n) = y}} \{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}.$$

Allora, usando la σ -additività,

$$\begin{aligned} \mathbb{P}(\{H(X_1, \dots, X_n) = y\}) &= \mathbb{P}\left(\bigcup_{\substack{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) \\ H(x_1, \dots, x_n) = y}} \{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}\right) \\ &= \sum_{\substack{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) \\ H(x_1, \dots, x_n) = y}} \mathbb{P}(\{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}). \end{aligned}$$

Segue che

$$\begin{aligned} \mathbb{E}(H(X_1, \dots, X_n)) &= \sum_{y \in R(H(X_1, \dots, X_n))} y \mathbb{P}(\{H(X_1, \dots, X_n) = y\}) \\ &= \sum_{y \in R(H(X_1, \dots, X_n))} y \sum_{\substack{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) \\ H(x_1, \dots, x_n) = y}} \mathbb{P}(\{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}) \\ &= \sum_{y \in R(H(X_1, \dots, X_n))} \sum_{\substack{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) \\ H(x_1, \dots, x_n) = y}} H(x_1, \dots, x_n) \mathbb{P}(\{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}) \\ &= \sum_{(x_1, \dots, x_n) \in R(X_1, \dots, X_n)} H(x_1, \dots, x_n) \mathbb{P}(\{(X_1, \dots, X_n) = (x_1, \dots, x_n)\}). \end{aligned}$$

□

Una conseguenza della proposizione precedente è la seguente.

PROPOSIZIONE 3.39. *Il valore atteso per variabili aleatorie discrete è lineare. Più precisamente, date due variabili aleatorie discrete $X_1, X_2: \Omega \rightarrow \mathbb{R}$ con valore atteso ben definito e $\lambda_1, \lambda_2 \in \mathbb{R}$, allora la variabile aleatoria $\lambda_1 X_1 + \lambda_2 X_2$ ha valore atteso ben definito e*

$$\mathbb{E}(\lambda_1 X_1 + \lambda_2 X_2) = \lambda_1 \mathbb{E}(X_1) + \lambda_2 \mathbb{E}(X_2).$$

DIMOSTRAZIONE. È sufficiente applicare la Proposizione 3.38 alle variabili aleatorie X_1, X_2 e alla funzione $H(x_1, x_2) = \lambda_1 x_1 + \lambda_2 x_2$. Utilizzando la Proposizione 3.33, segue

che

$$\begin{aligned}
\mathbb{E}(H(X_1, X_2)) &= \mathbb{E}(\lambda_1 X_1 + \lambda_2 X_2) = \sum_{(x_1, x_2) \in R(X_1, X_2)} (\lambda_1 x_1 + \lambda_2 x_2) \mathbb{P}(\{(X_1, X_2) = (x_1, x_2)\}) \\
&= \lambda_1 \sum_{(x_1, x_2) \in R(X_1, X_2)} x_1 \mathbb{P}(\{(X_1, X_2) = (x_1, x_2)\}) \\
&\quad + \lambda_2 \sum_{(x_1, x_2) \in R(X_1, X_2)} x_2 \mathbb{P}(\{(X_1, X_2) = (x_1, x_2)\}) \\
&= \lambda_1 \sum_{x_1 \in R(X_1)} x_1 \sum_{x_2 \in R(X_2)} \mathbb{P}(\{(X_1, X_2) = (x_1, x_2)\}) \\
&\quad + \lambda_2 \sum_{x_2 \in R(X_2)} x_2 \sum_{x_1 \in R(X_1)} \mathbb{P}(\{(X_1, X_2) = (x_1, x_2)\}) \\
&= \lambda_1 \sum_{x_1 \in R(X_1)} x_1 \mathbb{P}(\{X_1 = x_1\}) + \lambda_2 \sum_{x_2 \in R(X_2)} x_2 \mathbb{P}(\{X_2 = x_2\}).
\end{aligned}$$

□

OSSERVAZIONE 3.40. Grazie alla linearità del valore atteso, possiamo dedurre il comportamento del valore atteso rispetto a trasformazioni affini. Data una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ con valore atteso ben definito e dati $a, b \in \mathbb{R}$, si ha che

$$\mathbb{E}(aX + b) = a\mathbb{E}(X) + \mathbb{E}(b) = a\mathbb{E}(X) + b.$$

□

3.6. Variabili aleatorie assolutamente continue

In questa sezione spiegheremo come descrivere le leggi di variabili aleatorie che assumono valori in un range continuo. Studieremo, in particolare, variabili aleatorie con una densità.

DEFINIZIONE 3.41. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ si dice *assolutamente continua* se esiste una funzione $f_X: \mathbb{R} \rightarrow [0, +\infty)$ integrabile tale che

$$\mathbb{P}(\{X \in I\}) = \int_I f_X(x) dx$$

per ogni intervallo $I \subset \mathbb{R}$. La funzione f_X è detta *funzione di densità di probabilità* (abbreviato: fdp). Si veda la Figura 3.3. □




FIGURA 3.3. Esempio di funzione di densità di probabilità di una variabile aleatoria X . La probabilità che X appartenga all'intervallo I si ottiene dall'integrale della densità nell'intervallo I .

OSSERVAZIONE 3.42. Il nome stesso della funzione di densità di probabilità spiega il suo significato. Interpretando la probabilità come una massa, la funzione f_X è la densità di massa. Per calcolare la massa contenuta in un intervallo, si calcola l'integrale della densità.⁶ \square

OSSERVAZIONE 3.43. Poiché $\mathbb{P}(\{X \in \mathbb{R}\}) = 1$, segue che

$$\int_{\mathbb{R}} f_X(x) dx = 1.$$

Se questa condizione non è soddisfatta dall'integranda, allora questa non può essere una funzione densità di probabilità. \square

OSSERVAZIONE 3.44. Sia X una variabile assolutamente continua con funzione di densità di probabilità f_X . Sia $x \in R(X)$ un valore osservabile per la variabile aleatoria X . Nonostante x sia un valore che può essere assunto dalla variabile aleatoria X , la probabilità che X assuma esattamente il valore x è zero. Infatti

$$\mathbb{P}(\{X = x\}) = \mathbb{P}(\{X \in [x, x]\}) = \int_x^x f_X(t) dt = 0.$$

Questa è una caratteristica che differenzia le variabili aleatorie assolutamente continue dalle variabili aleatorie discrete. \square

OSSERVAZIONE 3.45. Nel caso di variabili aleatorie assolutamente continue, la funzione di distribuzione cumulativa $F_X: \mathbb{R} \rightarrow [0, 1]$ è la funzione

$$F_X(x) = \mathbb{P}(\{X \leq x\}) = \int_{-\infty}^x f_X(t) dt.$$

Per il Teorema Fondamentale del Calcolo Integrale, se f_X è continua in un intervallo (a, b) , allora F_X è derivabile nell'intervallo (a, b) e $F_X' = f_X$. \square

⁶Spiegazione con un approccio meno rigoroso e più fisico: se in un punto x c'è una densità $f_X(x)$, allora la massa di un intervallino $[x, x + dx]$ è $f_X(x)dx$. La massa totale si ottiene integrando sulle x .

⚠ Questa spiegazione non piace ai matematici.

OSSERVAZIONE 3.46. Il grafico della funzione di densità di probabilità di una variabile aleatoria rappresenta l'istogramma delle densità di frequenze relative tipico che si osserva su tante osservazioni della variabile aleatoria. Si veda la Figura 3.4.




FIGURA 3.4. La figura mette a confronto la funzione di densità di probabilità di una variabile aleatoria (la curva in nero) e l'istogramma delle densità di frequenze relative delle classi (a colori) per dati di un campione di 1000 osservazioni della variabile aleatoria. I dati sono stati raggruppati in 13 classi. Si può osservare come la funzione di densità di probabilità descriva l'andamento tipico dell'istogramma.

□

■ Link a slide animata in cui vengono confrontati il grafico della funzione di densità di probabilità di una variabile assolutamente continua e l'istogramma delle densità di frequenze relative di dati di un campione estratto dalla variabile aleatoria. <https://orlandopoliba.github.io/Manim-ProbStatPoliBA/Density/Density.html>

3.7. Vettori aleatori assolutamente continui con due componenti

Consideriamo in questa sezione vettori aleatori assolutamente continui con due componenti, ovvero un vettore aleatorio (X, Y) avente una legge congiunta descritta da una funzione di densità di probabilità $f_{(X,Y)}: \mathbb{R}^2 \rightarrow [0, +\infty)$. Più precisamente, per ogni insieme⁷ $E \subset \mathbb{R}^2$ si ha che

$$\mathbb{P}(\{X \in E\}) = \iint_E f_{(X,Y)}(x, y) dx dy.$$

Come per i vettori aleatori discreti, dalla legge congiunta di un vettore aleatorio è possibile determinare le leggi marginali di X e Y .

⁷Boreliano

PROPOSIZIONE 3.47. *Sia (X, Y) un vettore aleatorio assolutamente continuo con densità $f_{(X,Y)}$. Allora X e Y sono assolutamente continue con densità marginali f_X e f_Y date da*

$$f_X(x) = \int_{\mathbb{R}} f_{(X,Y)}(x, y) dy,$$

$$f_Y(y) = \int_{\mathbb{R}} f_{(X,Y)}(x, y) dx.$$

DIMOSTRAZIONE. Calcoliamo la funzione di distribuzione cumulativa di X . Per il teorema di Fubini-Tonelli abbiamo che

$$F_X(x) = \mathbb{P}(\{X \leq x\}) = \mathbb{P}(\{(X, Y) \in (-\infty, x] \times \mathbb{R}\}) = \iint_{(-\infty, x] \times \mathbb{R}} f_{(X,Y)}(t, y) dt dy$$

$$= \int_{-\infty}^x \left(\int_{\mathbb{R}} f_{(X,Y)}(t, y) dy \right) dt.$$

Derivando rispetto a x deduciamo che

$$f_X(x) = \int_{\mathbb{R}} f_{(X,Y)}(x, y) dy.$$

Per la densità marginale di Y la dimostrazione è del tutto analoga. \square

Come per le variabili discrete, se le componenti X e Y sono indipendenti è possibile ricostruire la legge congiunta.

PROPOSIZIONE 3.48. *Sia (X, Y) un vettore aleatorio assolutamente continuo con funzione di densità di probabilità congiunta data da $f_{(X,Y)}$. Siano f_X e f_Y le funzioni di densità di probabilità marginali di X e Y rispettivamente. Se X e Y sono indipendenti, allora*

$$f_{(X,Y)}(x, y) = f_X(x)f_Y(y), \text{ per ogni } x, y \in \mathbb{R}.$$

DIMOSTRAZIONE. Siano $x, y \in \mathbb{R}$. Da un lato abbiamo che

$$\mathbb{P}(\{X \leq x\} \cap \{Y \leq y\}) = \int_{-\infty}^y \int_{-\infty}^x f_{(X,Y)}(s, t) ds dt.$$

Dall'altro, per l'indipendenza,

$$\mathbb{P}(\{X \leq x\} \cap \{Y \leq y\}) = \mathbb{P}(\{X \leq x\})\mathbb{P}(\{Y \leq y\}) = \left(\int_{-\infty}^x f_X(s) ds \right) \left(\int_{-\infty}^y f_Y(t) dt \right),$$

quindi

$$\int_{-\infty}^y \int_{-\infty}^x f_{(X,Y)}(s, t) ds dt = \left(\int_{-\infty}^x f_X(s) ds \right) \left(\int_{-\infty}^y f_Y(t) dt \right)$$

per ogni x e y . Derivando rispetto a x e a y otteniamo la tesi. \square

Calcoliamo la densità di una somma di variabili aleatorie assolutamente continue.⁸

⁸ Ricordiamo la formula nel caso discreto per capire meglio la formula continua. Abbiamo fatto un conto simile a questo, ad esempio, per calcolare la legge della somma di due variabili aleatorie distribuite con legge binomiale o con legge di Poisson. Se X e Y sono variabili aleatorie discrete con range dato dai numeri interi \mathbb{Z} , allora la legge della somma si ottiene dalla legge congiunta di (X, Y) tramite la formula

$$\mathbb{P}(\{X + Y = k\}) = \sum_{h \in \mathbb{Z}} \mathbb{P}(\{X = h\} \cap \{Y = k - h\}).$$

PROPOSIZIONE 3.49. *Sia (X, Y) un vettore aleatorio assolutamente continuo con funzione di densità di probabilità congiunta $f_{(X,Y)}$. Allora $X + Y$ ha funzione di densità di probabilità*

$$f_{X+Y}(z) = \int_{-\infty}^{+\infty} f_{(X,Y)}(x, z - x) dx .$$

DIMOSTRAZIONE. Calcoliamo la funzione di distribuzione cumulativa di $X + Y$, ovvero

$$F_{X+Y}(z) = \mathbb{P}(\{X + Y \leq z\}) .$$

Consideriamo l'insieme del piano

$$D = \{(x, y) \in \mathbb{R}^2 \text{ tali che } x + y \leq z\} .$$

Segue che

$$\mathbb{P}(\{X + Y \leq z\}) = \mathbb{P}(\{(X, Y) \in D\}) = \iint_D f_{(X,Y)}(x, y) dx dy .$$

Il dominio di integrazione D è un dominio normale, si veda Figura 3.5.




FIGURA 3.5. Rappresentazione del dominio di integrazione usato nella dimostrazione.

L'integrale può essere calcolato nel seguente modo, applicando un cambio di variabili:

$$\begin{aligned} \iint_D f_{(X,Y)}(x, y) dx dy &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^{z-x} f_{(X,Y)}(x, y) dy \right) dx \quad \blacktriangleleft \text{ sostituzione } y = s - x \\ &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^z f_{(X,Y)}(x, s - x) ds \right) dx \\ &= \int_{-\infty}^z \left(\int_{-\infty}^{+\infty} f_{(X,Y)}(x, s - x) dx \right) ds . \end{aligned}$$

Per calcolare la densità di una somma, dobbiamo capire come è fatta la versione infinitesima della formula scritta sopra.

In conclusione,

$$F_{X+Y}(z) = \int_{-\infty}^z \left(\int_{-\infty}^{+\infty} f_{(X,Y)}(x, s-x) dx \right) ds.$$

Derivando rispetto a z otteniamo che

$$f_{X+Y}(z) = \int_{-\infty}^{+\infty} f_{(X,Y)}(x, z-x) dx.$$

□

PROPOSIZIONE 3.50. *Sia (X, Y) un vettore aleatorio assolutamente continuo con funzione di densità di probabilità congiunta $f_{(X,Y)}$ e tale con componenti X e Y indipendenti. Allora $X + Y$ ha funzione di densità di probabilità*

$$f_{X+Y}(z) = \int_{-\infty}^{+\infty} f_X(x) f_Y(z-x) dx.$$

DIMOSTRAZIONE. La formula segue direttamente dalla Proposizione 3.49 e dalla Proposizione 3.48. □

L'operazione che permette di calcolare la funzione di densità di probabilità della somma di due variabili aleatorie indipendenti è un'operazione nota.

DEFINIZIONE 3.51. Siano $f, g: \mathbb{R} \rightarrow \mathbb{R}$. La funzione

$$f * g(z) = \int_{-\infty}^{+\infty} f(x) g(z-x) dx$$

è detta *prodotto di convoluzione* tra f e g .⁹ □

► Si consiglia il video del canale di divulgazione 3Blue1Brown di Grant Sanderson sulla formula della densità della somma di due variabili aleatorie al seguente link: <https://youtu.be/IaSGqQa50-M?si=ntUjuJ3-Ztv71WR0>.

Sempre Grant Sanderson ha realizzato un bel video sul prodotto di convoluzione: https://www.youtube.com/watch?v=KuXjwB4LzSA&ab_channel=3Blue1Brown.

3.8. Valore atteso per variabili aleatorie assolutamente continue

Vogliamo fornire una nozione di valore atteso per variabili aleatorie definite tramite una densità. Descriviamo qui come si procede. Definiremo il valore atteso tramite un processo di limite.

Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria assolutamente continua con funzione di densità di probabilità f_X . Supponiamo per semplicità che $R(X)$ sia limitato e contenuto in un intervallo (a, b) . Approssimiamo la variabile aleatoria X con due variabili aleatorie discrete costruite nel seguente modo. Fissiamo $n \in \mathbb{N}$, $n \geq 1$. Consideriamo una suddivisione dell'intervallo (a, b) in n parti uguali

$$a = t_0 < t_1 < \dots < t_n = b, \quad t_k = a + k \frac{b-a}{n}.$$

⁹Il prodotto di convoluzione tra due funzioni di densità di probabilità è la versione infinitesima della formula discreta nella Nota a piè di pagina 8.

Definiamo la variabile aleatoria

$$\underline{X}_n(\omega) = t_k, \quad \text{se } X(\omega) \in [t_k, t_{k+1}).$$

Questa è una variabile discreta con range $R(\underline{X}_n) = \{t_0, t_1, \dots, t_{n-1}\}$. Calcoliamo la legge di \underline{X}_n . Abbiamo che

$$\mathbb{P}(\{\underline{X}_n = t_k\}) = \mathbb{P}(\{X \in [t_k, t_{k+1})\}) = \int_{t_k}^{t_{k+1}} f_X(x) dx.$$

Definiamo una seconda variabile aleatoria

$$\overline{X}_n(\omega) = t_{k+1}, \quad \text{se } X(\omega) \in [t_k, t_{k+1}).$$

Questa è una variabile discreta con range $R(\overline{X}_n) = \{t_1, t_1, \dots, t_n\}$. Calcoliamo la legge di \overline{X}_n . Abbiamo che

$$\mathbb{P}(\{\overline{X}_n = t_{k+1}\}) = \mathbb{P}(\{X \in [t_k, t_{k+1})\}) = \int_{t_k}^{t_{k+1}} f_X(x) dx.$$

Osserviamo che $\underline{X}_n \leq X \leq \overline{X}_n$, quindi una nozione di valore atteso per X deve essere compresa tra $\mathbb{E}(\underline{X}_n)$ e $\mathbb{E}(\overline{X}_n)$, che sappiamo definire in quanto variabili discrete. Abbiamo che

$$\begin{aligned} \mathbb{E}(\underline{X}_n) &= \sum_{k=0}^{n-1} t_k \mathbb{P}(\{\underline{X}_n = t_k\}) = \sum_{k=0}^{n-1} t_k \int_{t_k}^{t_{k+1}} f_X(x) dx \leq \sum_{k=0}^{n-1} \int_{t_k}^{t_{k+1}} x f_X(x) dx \\ &= \int_a^b x f_X(x) dx \\ &\leq \sum_{k=0}^{n-1} t_{k+1} \int_{t_k}^{t_{k+1}} f_X(x) dx = \sum_{k=0}^{n-1} t_{k+1} \mathbb{P}(\{\overline{X}_n = t_{k+1}\}) = \mathbb{E}(\overline{X}_n), \end{aligned}$$

ovvero

$$\mathbb{E}(\underline{X}_n) \leq \int_a^b x f_X(x) dx \leq \mathbb{E}(\overline{X}_n).$$

Inoltre la differenza tra $\mathbb{E}(\overline{X}_n)$ e $\mathbb{E}(\underline{X}_n)$ tende a zero, infatti

$$\begin{aligned} \mathbb{E}(\overline{X}_n) - \mathbb{E}(\underline{X}_n) &= \sum_{k=0}^{n-1} (t_{k+1} - t_k) \mathbb{P}(\{\underline{X}_n = t_k\}) = \sum_{k=0}^{n-1} \frac{b-a}{n} \int_{t_k}^{t_{k+1}} f_X(x) dx \\ &= \frac{b-a}{n} \int_a^b f_X(x) dx \rightarrow 0 \text{ as } n \rightarrow +\infty. \end{aligned}$$

Deduciamo che¹⁰

$$\lim_{n \rightarrow +\infty} \mathbb{E}(\underline{X}_n) = \lim_{n \rightarrow +\infty} \mathbb{E}(\overline{X}_n) = \int_a^b x f_X(x) dx.$$

Questa deduzione motiva la seguente definizione.

¹⁰È un esercizio di Analisi 1!

DEFINIZIONE 3.52. Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria assolutamente continua con funzione di densità di probabilità f_X . Il *valore atteso* di X è, se ben definito,¹¹ il numero

$$\mathbb{E}(X) := \int_{\mathbb{R}} x f_X(x) dx.$$

□

OSSERVAZIONE 3.53. Ricordiamo la formula ricavata nella parte di statistica descrittiva per l'approssimazione della media per dati raggruppati in classi. La formula è una media pesata dei valori centrali delle classi pesate per le aree dei rettangoli dell'istogramma delle densità di frequenze relative. Poiché il grafico della funzione di densità di probabilità rappresenta l'istogramma delle densità di frequenze relative tipico su tante osservazioni della variabile aleatoria, capiamo che la formula per l'approssimazione della media per dati raggruppati in classi è una versione approssimata e adattata ai dati di un campione della formula $\int_{\mathbb{R}} x f_X(x) dx$. □

Il valore atteso per variabili assolutamente continue verifica tutte le proprietà che abbiamo dimostrato nel caso di variabili discrete.

Partiamo con il dimostrare la linearità

PROPOSIZIONE 3.54. *Siano X e Y due variabili aleatorie assolutamente continue con densità f_X e f_Y rispettivamente (e con valori attesi ben definiti). Allora $(X + Y)$ ha valore atteso ben definito e) $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y)$.*

DIMOSTRAZIONE. Dalla Proposizione 3.49 ricaviamo la densità della somma, ovvero

$$f_{X+Y}(z) = \int_{-\infty}^{+\infty} f_{(X,Y)}(x, z-x) dx.$$

Per definizione di valore atteso nel caso di variabili aleatorie assolutamente continue

¹¹Intendiamo che la funzione $|x|f_X(x)$ ha integrale finito.

abbiamo quindi che

$$\begin{aligned} \mathbb{E}(X + Y) &= \int_{-\infty}^{+\infty} z f_{X+Y}(z) dz = \int_{-\infty}^{+\infty} z \left(\int_{-\infty}^{+\infty} f_{(X,Y)}(x, z-x) dx \right) dz \\ &\quad \blackleftarrow{\text{cambiamo ordine di integrazione}} \\ &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^{+\infty} z f_{(X,Y)}(x, z-x) dz \right) dx \\ &\quad \blackleftarrow{\text{sostituzione } y = z - x} \\ &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^{+\infty} (y+x) f_{(X,Y)}(x, y) dy \right) dx \\ &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^{+\infty} y f_{(X,Y)}(x, y) dy \right) dx + \int_{-\infty}^{+\infty} \left(x \int_{-\infty}^{+\infty} f_{(X,Y)}(x, y) dy \right) dx \\ &\quad \blackleftarrow{\text{nel primo integrale cambiamo ordine di integrazione}} \\ &\quad \blackleftarrow{\text{nel secondo integrale usiamo la Proposizione 3.47}} \\ &= \int_{-\infty}^{+\infty} \left(y \int_{-\infty}^{+\infty} f_{(X,Y)}(x, y) dx \right) dy + \int_{-\infty}^{+\infty} x f_X(x) dx \\ &\quad \blackleftarrow{\text{nel secondo integrale usiamo la Proposizione 3.47}} \\ &= \int_{-\infty}^{+\infty} y f_Y(y) dy + \int_{-\infty}^{+\infty} x f_X(x) dx \\ &= \mathbb{E}(Y) + \mathbb{E}(X). \end{aligned}$$

□

Calcoliamo il valore atteso di una funzione di una variabile aleatoria.

PROPOSIZIONE 3.55. *Sia X una variabile aleatoria assolutamente continua con funzione di densità di probabilità f_X . Sia $H: \mathbb{R} \rightarrow \mathbb{R}$ una funzione derivabile e strettamente monotona. Allora*

$$\mathbb{E}(H(X)) = \int_{-\infty}^{+\infty} H(x) f_X(x) dx.$$

DIMOSTRAZIONE. Supponiamo che H sia strettamente crescente. La dimostrazione nel caso in cui H sia strettamente decrescente è del tutto analoga. Calcoliamo la funzione di distribuzione cumulativa di $H(X)$. Da un lato abbiamo che

$$F_{H(X)}(y) = \int_{-\infty}^y f_{H(X)}(t) dt.$$

Dall'altro

$$F_{H(X)}(y) = \mathbb{P}(\{H(X) \leq y\})$$

☛ usiamo il fatto che H è strettamente crescente

$$= \mathbb{P}(\{X \leq H^{-1}(y)\}) = \int_{-\infty}^{H^{-1}(y)} f_X(s) ds$$

☛ cambio di variabile $t = H(s) \implies dt = H'(s)ds$

$$= \int_{-\infty}^y f_X(H^{-1}(t))H'(H^{-1}(t))^{-1} dt$$

Derivando in y segue che

$$f_{H(X)}(y) = f_X(H^{-1}(y))|H'(H^{-1}(y))^{-1}|.$$

Possiamo ora calcolare il valore atteso:

$$\mathbb{E}(H(X)) = \int_{-\infty}^{+\infty} y f_{H(X)}(y) dy = \int_{-\infty}^{+\infty} y f_X(H^{-1}(y))H'(H^{-1}(y))^{-1} dy$$

☛ cambio di variabile $y = H(x) \implies dy = H'(x)dx$

$$= \int_{-\infty}^{+\infty} H(x) f_X(x) dx.$$

□

OSSERVAZIONE 3.56. La formula ottenuta nella Proposizione 3.55 è valida anche in casi più generali. Ad esempio, se la funzione H è derivabile e strettamente monotona a tratti, il risultato si può applicare ad ogni tratto in cui H è derivabile e strettamente monotona.

Vediamolo in un caso concreto che utilizzeremo spesso in seguito. Sia X una variabile aleatoria assolutamente continua con densità f_X e calcoliamo il valore atteso di X^2 . Osserviamo che $H(x) = x^2$ non è monotona. Calcoliamo la densità di X^2 . Per $y \geq 0$ abbiamo che

$$\begin{aligned} F_{X^2}(y) - F_{X^2}(0) &= \mathbb{P}(\{0 \leq X^2 \leq y\}) = \mathbb{P}(\{-\sqrt{y} \leq X \leq \sqrt{y}\}) = \int_{-\sqrt{y}}^{\sqrt{y}} f_X(s) ds \\ &= \int_{-\sqrt{y}}^0 f_X(s) ds + \int_0^{\sqrt{y}} f_X(s) ds. \end{aligned}$$

Calcoliamo il secondo integrale

$$\int_0^{\sqrt{y}} f_X(s) ds$$

☛ cambio di variabile $s = \sqrt{t} \implies ds = \frac{1}{2\sqrt{t}} dt$

$$= \int_0^y f_X(\sqrt{t}) \frac{1}{2\sqrt{t}} dt.$$

Analogamente

$$\int_{-\sqrt{y}}^0 f_X(s) ds$$

☛ cambio di variabile $s = -\sqrt{t} \implies ds = -\frac{1}{2\sqrt{t}} dt$

$$= \int_0^y f_X(-\sqrt{t}) \frac{1}{2\sqrt{t}} dt.$$

Concludiamo che

$$F_{X^2}(y) - F_{X^2}(0) = \int_0^y f_X(\sqrt{t}) \frac{1}{2\sqrt{t}} dt + \int_0^y f_X(-\sqrt{t}) \frac{1}{2\sqrt{t}} dt.$$

Derivando in y otteniamo che

$$f_{X^2}(y) = f_X(\sqrt{y}) \frac{1}{2\sqrt{y}} + f_X(-\sqrt{y}) \frac{1}{2\sqrt{y}}.$$

Possiamo allora calcolare

$$\mathbb{E}(X^2) = \int_0^{+\infty} y f_{X^2}(y) dy = \int_0^{+\infty} y f_X(\sqrt{y}) \frac{1}{2\sqrt{y}} dy + \int_0^{+\infty} y f_X(-\sqrt{y}) \frac{1}{2\sqrt{y}} dy$$

☛ cambio di variabile

$$= \int_{-\infty}^{+\infty} x^2 f_X(x) dx.$$

□

3.9. Varianza, deviazione standard e covarianza per variabili aleatorie discrete

Introduciamo una quantità che permette di misurare quanto tipicamente la variabile aleatoria X devia quadraticamente dal suo valore atteso.

DEFINIZIONE 3.57. Sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria. La *varianza* di X è, se ben definita,¹² il numero

$$\text{Var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2).$$

La *deviazione standard* di X è $\sqrt{\text{Var}(X)}$. Talvolta viene utilizzato il simbolo $\sigma(X) = \sqrt{\text{Var}(X)}$. □

OSSERVAZIONE 3.58. Una formula alternativa per la varianza è

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2. \quad (3.1)$$

Infatti, sviluppando il quadrato nella definizione della varianza e utilizzando la linearità del valore atteso, otteniamo che

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(X^2 + \mathbb{E}(X)^2 - 2X\mathbb{E}(X)) \\ &= \mathbb{E}(X^2) + \mathbb{E}(X)^2 - 2\mathbb{E}(X)\mathbb{E}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2. \end{aligned}$$

□

¹²Ovvero, se $(X - \mathbb{E}(X))^2$ ha valore atteso finito.

OSSERVAZIONE 3.59. Se X è una variabile aleatoria discreta, allora

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \sum_{x \in R(X)} x^2 \mathbb{P}(\{X = x\}) - \mathbb{E}(X)^2.$$

Se X è una variabile aleatoria assolutamente continua con funzione di densità di probabilità f_X , allora

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \int_{-\infty}^{+\infty} x^2 f_X(x) dx - \mathbb{E}(X)^2.$$

□

OSSERVAZIONE 3.60. Deduciamo il comportamento della varianza rispetto a trasformazioni affini. Utilizzando la linearità del valore atteso, otteniamo che

$$\begin{aligned} \text{Var}(aX + b) &= \mathbb{E}((aX + b - \mathbb{E}(aX + b))^2) = \mathbb{E}((aX + b - a\mathbb{E}(X) - b)^2) \\ &= \mathbb{E}((aX - a\mathbb{E}(X))^2) = a^2 \mathbb{E}((X - \mathbb{E}(X))^2) = a^2 \text{Var}(X). \end{aligned}$$

In particolare,

$$\sigma(aX + b) = |a| \sigma(X).$$

□

DEFINIZIONE 3.61. Siano $X, Y: \Omega \rightarrow \mathbb{R}$ due variabili aleatorie. La *covarianza* di X e Y è, se ben definita,¹³ il numero

$$\text{Cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))).$$

Talvolta viene utilizzato il simbolo $\sigma(X, Y) = \text{Cov}(X, Y)$.

□

OSSERVAZIONE 3.62. Una formula alternativa per la covarianza è

$$\text{Cov}(X, Y) = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y).$$

Infatti, sviluppando il prodotto nella definizione della covarianza e utilizzando la linearità del valore atteso, otteniamo che

$$\begin{aligned} \text{Cov}(X, Y) &= \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))) \\ &= \mathbb{E}(XY - X\mathbb{E}(Y) - Y\mathbb{E}(X) + \mathbb{E}(X)\mathbb{E}(Y)) \\ &= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y) - \mathbb{E}(X)\mathbb{E}(Y) + \mathbb{E}(X)\mathbb{E}(Y) \\ &= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y). \end{aligned}$$

□

OSSERVAZIONE 3.63. Deriviamo alcune proprietà della covarianza.

1. $\text{Cov}(X, Y) = \text{Cov}(Y, X)$, ovvero la covarianza è simmetrica. Segue semplicemente dalla definizione.

2. $\text{Cov}(X, X) = \text{Var}(X)$. Segue semplicemente dalla definizione.

¹³Ovvero, se $(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))$ ha valore atteso finito.

3. $\text{Cov}(\lambda_1 X_1 + \lambda_2 X_2, Y) = \lambda_1 \text{Cov}(X_1, Y) + \lambda_2 \text{Cov}(X_2, Y)$, ovvero la covarianza è lineare rispetto a ciascuno dei suoi argomenti. Infatti, utilizzando la linearità del valore atteso e sviluppando il prodotto,

$$\begin{aligned} \text{Cov}(\lambda_1 X_1 + \lambda_2 X_2, Y) &= \mathbb{E}\left(\left(\lambda_1 X_1 + \lambda_2 X_2 - \mathbb{E}(\lambda_1 X_1 + \lambda_2 X_2)\right)(Y - \mathbb{E}(Y))\right) \\ &= \mathbb{E}\left(\left(\lambda_1 X_1 + \lambda_2 X_2 - \lambda_1 \mathbb{E}(X_1) - \lambda_2 \mathbb{E}(X_2)\right)(Y - \mathbb{E}(Y))\right) \\ &= \mathbb{E}\left(\left(\lambda_1 X_1 - \lambda_1 \mathbb{E}(X_1)\right)(Y - \mathbb{E}(Y)) + \left(\lambda_2 X_2 - \lambda_2 \mathbb{E}(X_2)\right)(Y - \mathbb{E}(Y))\right) \\ &= \lambda_1 \mathbb{E}\left(\left(X_1 - \mathbb{E}(X_1)\right)(Y - \mathbb{E}(Y))\right) + \lambda_2 \mathbb{E}\left(\left(X_2 - \mathbb{E}(X_2)\right)(Y - \mathbb{E}(Y))\right) \\ &= \lambda_1 \text{Cov}(X_1, Y) + \lambda_2 \text{Cov}(X_2, Y). \end{aligned}$$

□

PROPOSIZIONE 3.64. *Se X e Y sono variabili aleatorie indipendenti, allora $\text{Cov}(X, Y) = 0$.*

DIMOSTRAZIONE. Dimostriamolo nel caso in cui le due variabili aleatorie siano discrete. Calcoliamo il valore atteso di $H(X, Y)$ dove $H(x, y) = xy$ utilizzando la Proposizione 3.38. Per l'indipendenza otteniamo che

$$\begin{aligned} \mathbb{E}(XY) &= \sum_{\substack{x \in R(X) \\ y \in R(Y)}} xy \mathbb{P}(\{X = x\} \cap \{Y = y\}) \\ &= \sum_{y \in R(Y)} \sum_{x \in R(X)} xy \mathbb{P}(\{X = x\}) \mathbb{P}(\{Y = y\}) \\ &= \left(\sum_{x \in R(X)} x \mathbb{P}(\{X = x\}) \right) \left(\sum_{y \in R(Y)} y \mathbb{P}(\{Y = y\}) \right) \\ &= \mathbb{E}(X) \mathbb{E}(Y). \end{aligned}$$

La dimostrazione nel caso di variabili assolutamente continue X e Y con funzioni di densità di probabilità f_X e f_Y rispettivamente si basa sul fatto che¹⁴

$$\begin{aligned} \mathbb{E}(XY) &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xy f_{(X,Y)}(x, y) \, dx dy \\ &\quad \blacktriangleright \text{applicando la Proposizione 3.48} \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xy f_X(x) f_Y(y) \, dx dy \\ &\quad \blacktriangleright \text{applicando il Teorema di Fubini-Tonelli} \\ &= \left(\int_{-\infty}^{+\infty} x f_X(x) \, dx \right) \left(\int_{-\infty}^{+\infty} y f_Y(y) \, dy \right) = \mathbb{E}(X) \mathbb{E}(Y). \end{aligned}$$

□

L'implicazione opposta non è sempre vera, come mostra il seguente esempio.

¹⁴Non abbiamo dimostrato questa formula, ma se si è capito il significato di densità si può comprendere.

ESEMPIO 3.65. Esibiamo qui due variabili aleatorie X e Y con covarianza nulla non indipendenti. Consideriamo una variabile aleatoria X con range $R(X) = \{-1, 0, 1\}$ con la seguente legge:

$$\mathbb{P}(\{X = -1\}) = \mathbb{P}(\{X = 0\}) = \mathbb{P}(\{X = 1\}) = \frac{1}{3}.$$

Osserviamo che

$$\mathbb{E}(X) = -1 \cdot \mathbb{P}(\{X = -1\}) + 0 \cdot \mathbb{P}(\{X = 0\}) + 1 \cdot \mathbb{P}(\{X = 1\}) = 0.$$

Consideriamo la variabile $Y = X^2$. Allora

$$\begin{aligned} \text{Cov}(X, Y) &= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y) = \mathbb{E}(X^3) \\ &= (-1)^3 \cdot \mathbb{P}(\{X = -1\}) + 0^3 \cdot \mathbb{P}(\{X = 0\}) + 1^3 \cdot \mathbb{P}(\{X = 1\}) \\ &= 0. \end{aligned}$$

Tuttavia

$$\mathbb{P}(\{Y = 0\}|\{X = 0\}) = 1 \neq \mathbb{P}(\{Y = 0\}) = \frac{1}{3},$$

quindi le variabili aleatorie sono dipendenti. □

Osserviamo che la varianza non è lineare. La varianza della somma di variabili aleatorie non è, in generale, la somma delle varianze delle variabili aleatorie.

ESEMPIO 3.66. Consideriamo una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ e $Y = X$. Allora

$$\text{Var}(X + Y) = \text{Var}(X + X) = \text{Var}(2X) = 4\text{Var}(X) \neq \text{Var}(X) + \text{Var}(X).$$

□

La formula generale è la seguente.

PROPOSIZIONE 3.67. *Siano X, Y due variabili aleatorie con varianza ben definita. Allora*

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2\text{Cov}(X, Y).$$

DIMOSTRAZIONE. Riscriviamo la varianza utilizzando la covarianza e utilizziamo la linearità della covarianza rispetto a ogni suo argomento e la simmetria per ottenere che

$$\begin{aligned} \text{Var}(X + Y) &= \text{Cov}(X + Y, X + Y) = \text{Cov}(X, X + Y) + \text{Cov}(Y, X + Y) \\ &= \text{Cov}(X, X) + \text{Cov}(X, Y) + \text{Cov}(Y, X) + \text{Cov}(Y, Y) \\ &= \text{Var}(X) + 2\text{Cov}(X, Y) + \text{Var}(Y). \end{aligned}$$

□

OSSERVAZIONE 3.68. Ricordando che variabili aleatorie indipendenti hanno covarianza nulla per la Proposizione 3.64, otteniamo il seguente fatto. Siano X_1, \dots, X_n variabili aleatorie indipendenti con varianza ben definita. Allora, per la linearità della covarianza rispetto a ogni suo argomento,

$$\begin{aligned} &\text{Var}(X_1 + X_2 + \dots + X_n) \\ &= \text{Var}(X_1) + \text{Var}(X_2 + \dots + X_n) + 2\text{Cov}(X_1, X_2 + \dots + X_n) \\ &= \text{Var}(X_1) + \text{Var}(X_2 + \dots + X_n) + 2\text{Cov}(X_1, X_2) + \dots + 2\text{Cov}(X_1, X_n). \end{aligned}$$

Per l'indipendenza tra X_1, \dots, X_n e la Proposizione 3.29, otteniamo che

$$\text{Var}(X_1 + X_2 + \dots + X_n) = \text{Var}(X_1) + \text{Var}(X_2 + \dots + X_n).$$

Iterando il procedimento, otteniamo che

$$\text{Var}(X_1 + X_2 + \dots + X_n) = \text{Var}(X_1) + \text{Var}(X_2) + \dots + \text{Var}(X_n).$$

□

3.9.1. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 3.69. Sia $X = (X_1, X_2)$ un vettore aleatorio di tipo discreto con range

$$\{(-1, -1), (0, -1), (1, -1), (-1, 0), (1, 0), (0, 1), (1, 1)\}.$$

Si sa che $\mathbb{P}(X_1 = -1, X_2 = -1) = \frac{1}{6}$, $\mathbb{P}(X_1 = 1, X_2 = 0) = \frac{1}{3}$, $\mathbb{P}(X_1 = 0, X_2 = 1) = \frac{1}{4}$ e che gli altri valori che possono essere assunti sono equiprobabili.

- (1) Calcolare la probabilità che $X_1 > 0$ sapendo che si è verificato l'evento $X_2 < 0$.
- (2) Stabilire se X_1 e X_2 sono indipendenti.
- (3) Calcolare il valore atteso della variabile aleatoria $Y = \max\{X_1, X_2\}$.

□

ESERCIZIO 3.70. Siano $\lambda, \mu \in \mathbb{R}$ due parametri e sia (X, Y) una vettore aleatorio discreto con le seguenti probabilità congiunte:

	Y	0	1	2
X				
0	λ	1/8	1/16	
1	1/4	μ	1/4	

- (1) Calcolare $\text{Cov}(X, Y)$.
- (2) Per quali valori di λ e μ le variabili aleatorie X e Y sono indipendenti?

□

ESERCIZIO 3.71. Sia (X_1, X_2) il vettore aleatorio con la seguente funzione di probabilità congiunta:

	X_1	-1	0	1
X_2				
-1	a	1/16	0	
0	1/16	b	1/16	
1	0	1/8	c	

con $a, b, c \in \mathbb{R}$.

- (1) Determinare a, b, c tali che $\mathbb{E}(X_1) = 0$ e $\text{Var}(X_2) = \frac{207}{256}$.
- (2) Calcolare la probabilità che $X_1 + X_2 > 0$.
- (3) Calcolare la probabilità che $X_1 + X_2 > 0$ sapendo che si è verificato $X_2 > 0$.

□

ESERCIZIO 3.72. Una variabile aleatoria continua X assume valori nell'intervallo $[-\frac{\pi}{2}, \frac{\pi}{2}]$ e ha come Funzione di Distribuzione Cumulativa (FDC) una funzione continua $F: \mathbb{R} \rightarrow \mathbb{R}$ che verifica

$$F(x) = a \sin(x) + b \quad \text{per ogni } x \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right],$$

dove $a, b \in \mathbb{R}$.

- (1) Si determinino i valori a e b in modo che $F(x)$ soddisfi le proprietà di Funzione di Distribuzione Cumulativa. Si descriva la funzione F anche fuori dall'intervallo $[-\frac{\pi}{2}, \frac{\pi}{2}]$.
- (2) Calcolare $\mathbb{P}(0 \leq X \leq 6)$.
- (3) Determinare la funzione di densità di probabilità (f.d.p.) $f: \mathbb{R} \rightarrow \mathbb{R}$ di X .
- (4) Calcolare $\mathbb{E}(X)$.

□

ESERCIZIO 3.73. Sia X una variabile aleatoria continua avente la seguente funzione di densità di probabilità

$$f(x) = \begin{cases} \frac{1}{|x| + k} & \text{se } |x| < a, \\ 0 & \text{altrimenti,} \end{cases}$$

dove $k > 0$ e $a > 0$.

- (1) Determinare il valore dei parametri k e a per cui f sia una densità di probabilità tale che X soddisfi a $\mathbb{P}(X > 1) = 1/3$.
- (2) Calcolare valore atteso e varianza di X . (Si consiglia di effettuare i conti sostituendo il valore esplicito di k e a solo alla fine.)
- (3) Calcolare la probabilità che $X < 1$ sapendo che si è verificato l'evento $X > 0$.

□

ESERCIZIO 3.74. Siano $a \in (0, 1)$ e $b \in \mathbb{R}$ due parametri e sia X una variabile aleatoria distribuita con una densità di probabilità $f: \mathbb{R} \rightarrow \mathbb{R}$ definita da

$$f(x) := \begin{cases} b a^x & \text{per } x \geq 0 \\ 0 & \text{altrimenti.} \end{cases}$$

Trovare a e b tali che $\mathbb{E}(X) = 2$.

□

ESERCIZIO 3.75. Siano X_1 e X_2 due variabile aleatorie indipendenti con densità

$$f_1(x) = \begin{cases} e^{-x} & \text{se } x > 0, \\ 0 & \text{altrimenti,} \end{cases} \quad f_2(x) = \begin{cases} x & \text{se } 0 < x < \sqrt{2}, \\ 0 & \text{altrimenti,} \end{cases}$$

rispettivamente. Sia $Y = \min\{X_1, X_2\}$. Calcolare la probabilità che $Y > 1$.

□

ESERCIZIO 3.76. Sia (X, Y) un vettore aleatorio con la seguente densità congiunta:

$$f(x, y) = \begin{cases} x e^{-x-y} & \text{se } x > 0, y > 0, \\ 0 & \text{altrimenti.} \end{cases}$$

- (1) Calcolare la densità di X e di Y .
- (2) Le due variabili X e Y sono indipendenti?

□

ESERCIZIO 3.77. Sia (X, Y) un vettore aleatorio con la seguente densità congiunta:

$$f(x, y) = \begin{cases} C & \text{se } 0 < y < x < 1, \\ 0 & \text{altrimenti.} \end{cases}$$

- (1) Si determini C in modo che f sia una densità di probabilità.
- (2) Si calcoli la funzione di densità di probabilità marginale g di X .
- (3) Si calcoli la funzione di densità di probabilità marginale h di Y .
- (4) Le variabili aleatorie X e Y sono indipendenti?

□

CAPITOLO 4

Leggi discrete

Contenuti

4.1. Legge di Bernoulli	109
4.2. Legge binomiale	110
Esercizi	113
4.2.1. La scimmia instancabile di Borel	114
4.3. Legge di Poisson	117
Esercizi	121
4.4. Legge geometrica	122
Esercizi	127

In questo capitolo descriviamo alcune leggi discrete.

4.1. Legge di Bernoulli

Consideriamo una variabile aleatoria che descrive un successo in un tentativo.

DEFINIZIONE 4.1. (Legge di Bernoulli) Sia $p \in [0, 1]$. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ si dice *distribuita con legge di Bernoulli con parametro p* se $R(X) = \{0, 1\}$ e

$$\mathbb{P}(\{X = 1\}) = p, \quad \mathbb{P}(\{X = 0\}) = 1 - p.$$

Scriveremo $X \sim \text{Be}(p)$. □

OSSERVAZIONE 4.2. Calcoliamo il valore atteso di una variabile aleatoria $X \sim \text{Be}(p)$

$$\mathbb{E}(X) = 1 \cdot \mathbb{P}(\{X = 1\}) + 0 \cdot \mathbb{P}(\{X = 0\}) = 1 \cdot p + 0 \cdot (1 - p) = p.$$
□

■◀ Link a slide animata in cui vengono generate molte osservazioni di una variabile aleatoria distribuita con legge di Bernoulli: <https://orlandopoliba.github.io/Manim-ProbStatPoliBA/Bernoulli/Bernoulli.html>

OSSERVAZIONE 4.3. Calcoliamo la varianza di una variabile aleatoria $X \sim \text{Be}(p)$:

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = 1^2 \cdot \mathbb{P}(\{X = 1\}) + 0^2 \cdot \mathbb{P}(\{X = 0\}) - p^2 = 1^2 \cdot p - p^2 = p(1 - p).$$

Si veda la Figura 4.1.




FIGURA 4.1. Grafico della varianza di leggi di Bernoulli in funzione del parametro p . La varianza massima si ha per $p = \frac{1}{2}$.

□



FIGURA 4.2. Jakob Bernoulli (1654-1705).^a Uno dei membri della famiglia Bernoulli. Nella sua opera *Ars Conjectandi* (1713) ottiene una delle prime formulazioni della legge dei grandi numeri, un teorema fondamentale che studieremo nell'ultima parte del corso.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Jakob_Bernoulli.jpg

4.2. Legge binomiale

La legge binomiale descrive il numero di successi in n tentativi, ciascuno con probabilità di successo p .

DEFINIZIONE 4.4. (Legge binomiale) Siano $n \in \mathbb{N} \setminus \{0\}$ e $p \in [0, 1]$. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ si dice *distribuita con legge binomiale con parametri n e p* se è identicamente distribuita a $X_1 + \dots + X_n$ dove $X_1, \dots, X_n \sim \text{Be}(p)$ sono indipendenti. Scriveremo $X \sim B(n, p)$. □

■◀ Link a slide animata in cui vengono generate molte osservazioni di una variabile aleatoria distribuita con legge binomiale: <https://orlandopoliba.github.io/Manim-ProbStatPoliBA/Binomial/Binomial.html>

In Figura 4.3 si può vedere un esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge binomiale.




FIGURA 4.3. Esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge binomiale.

◀/▶ Link a grafico interattivo in cui si può studiare l'aspetto della funzione di massa di probabilità della legge binomiale al variare di n e p : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/binomial.html

PROPOSIZIONE 4.5. Sia $X \sim B(n, p)$. Allora $R(X) = \{0, 1, \dots, n\}$ e

$$\mathbb{P}(\{X = k\}) = \binom{n}{k} p^k (1-p)^{n-k}, \quad \text{per } k = 0, 1, \dots, n.$$

DIMOSTRAZIONE. Per definizione X è identicamente distribuita a $X_1 + \dots + X_n$ con $X_1, \dots, X_n \sim \text{Be}(p)$ indipendenti. Segue immediatamente che $R(X) = \{0, 1, \dots, n\}$. Calcoliamo

$$\mathbb{P}(\{X = k\}) = \mathbb{P}(\{X_1 + \dots + X_n = k\}).$$

Poiché X_1, \dots, X_n possono assumere solamente i valori 0 e 1, la loro somma è uguale a k se k tra le X_1, \dots, X_n assumono il valore 1 (probabilità p^k) e le restanti $n - k$ assumono il valore 0 (probabilità $(1-p)^{n-k}$). In tutto ci sono $\binom{n}{k}$ modi distinti di scegliere le k variabili di Bernoulli che sono uguali a 1. Questo conclude la dimostrazione. \square

Nel risultato seguente dimostriamo il seguente fatto che è di facile intuizione. Consideriamo una prova con probabilità di successo p . Consideriamo un gruppo di n prove indipendenti (descritte da una legge binomiale $B(n, p)$) e, separatamente, un gruppo di m prove indipendenti (descritte da una legge binomiale $B(m, p)$). Se il primo gruppo di prove e il secondo gruppo di prove sono indipendenti, allora è come fare in tutto $n + m$ prove indipendenti (descritte da una legge binomiale $B(n + m, p)$). Ispezionando la dimostrazione del risultato, ci rendiamo conto che ricalca esattamente questa idea.

PROPOSIZIONE 4.6. Siano $X \sim B(n, p)$ e $Y \sim B(m, p)$ indipendenti. Allora $X + Y \sim B(n + m, p)$.

DIMOSTRAZIONE. Consideriamo $n + m$ variabili aleatorie di Bernoulli tra loro indipendenti $X_1, \dots, X_n, Y_1, \dots, Y_m \sim \text{Be}(p)$. Definiamo

$$X' = X_1 + \dots + X_n \sim B(n, p), \quad Y' = Y_1 + \dots + Y_m \sim B(m, p).$$

Osserviamo che i vettori aleatori (X_1, \dots, X_n) e (Y_1, \dots, Y_m) sono tra loro indipendenti, quindi X' e Y' sono tra loro indipendenti per la Proposizione 3.29. Inoltre

$$X' + Y' = X_1 + \dots + X_n + Y_1 + \dots + Y_m \sim B(n + m, p). \quad (4.1)$$

Possiamo allora calcolare per $k = 0, \dots, m + n$

$$\begin{aligned} \mathbb{P}(\{X + Y = k\}) & \quad \blacksquare \text{ decomponendo } k \\ &= \mathbb{P}\left(\bigcup_{h=0}^k \{X = h\} \cap \{Y = k - h\}\right) \quad \blacksquare \text{ eventi disgiunti} \\ &= \sum_{h=0}^k \mathbb{P}(\{X = h\} \cap \{Y = k - h\}) \quad \blacksquare \text{ indipendenza} \\ &= \sum_{h=0}^k \mathbb{P}(\{X = h\})\mathbb{P}(\{Y = k - h\}) \quad \blacksquare \text{ i.d. a } X' \text{ e } Y' \\ &= \sum_{h=0}^k \mathbb{P}(\{X' = h\})\mathbb{P}(\{Y' = k - h\}) \quad \blacksquare \text{ indipendenza} \\ &= \sum_{h=0}^k \mathbb{P}(\{X = h\} \cap \{Y = k - h\}) \quad \blacksquare \text{ eventi disgiunti} \\ &= \mathbb{P}\left(\bigcup_{h=0}^k \{X = h\} \cap \{Y = k - h\}\right) \quad \blacksquare \text{ decomponendo } k \\ &= \mathbb{P}(\{X' + Y' = k\}) \quad \blacksquare \text{ per la (4.1)} \\ &= \binom{n + m}{k} p^k (1 - p)^{n+m-k}. \end{aligned}$$

Questo conclude la dimostrazione. □

PROPOSIZIONE 4.7. *Sia $X \sim B(n, p)$. Allora*

$$\mathbb{E}(X) = np.$$

DIMOSTRAZIONE. La variabile aleatoria X è identicamente distribuita a $X_1 + \dots + X_n$ dove $X_1, \dots, X_n \sim \text{Be}(p)$. Ricordiamo che $\mathbb{E}(X_i) = p$. Allora, per la linearità del valore atteso,

$$\mathbb{E}(X) = \mathbb{E}(X_1 + \dots + X_n) = \mathbb{E}(X_1) + \dots + \mathbb{E}(X_n) = \underbrace{p + \dots + p}_{n \text{ volte}} = np.$$

□

PROPOSIZIONE 4.8. *Sia $X \sim B(n, p)$. Allora*

$$\text{Var}(X) = np(1 - p).$$

DIMOSTRAZIONE. La variabile aleatoria X è identicamente distribuita a $X_1 + \dots + X_n$ dove $X_1, \dots, X_n \sim \text{Be}(p)$ sono indipendenti. Ricordiamo che $\text{Var}(X_i) = p$. Per

l'Osservazione 3.68, sfruttiamo l'indipendenza per ottenere che

$$\begin{aligned}\text{Var}(X) &= \text{Var}(X_1 + \cdots + X_n) = \text{Var}(X_1) + \cdots + \text{Var}(X_n) \\ &= \underbrace{p(1-p) + \cdots + p(1-p)}_{n \text{ volte}} = np(1-p).\end{aligned}$$

□

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 4.9. Trovare la probabilità che, lanciando tre volte una moneta, compaiano: (a) 3 teste, (b) 2 croci e 1 testa, (c) almeno 1 testa, (d) non più di 1 croce. □

ESERCIZIO 4.10. Trovare la probabilità che in cinque lanci di un dado equilibrato, un 3 appaia (a) due volte, (b) al massimo una volta, (c) almeno due volte. □

ESERCIZIO 4.11. Se il 20% dei bulloni prodotti da una macchina è difettoso, determinare la probabilità che su 4 bulloni scelti a caso, (a) 1, (b) 0, (c) meno di 2 bulloni siano difettosi. □

ESERCIZIO 4.12. Trovare la probabilità di ottenere una somma uguale a 7 almeno una volta in tre lanci di una coppia di dadi equilibrati. □

ESERCIZIO 4.13. Una pianta produce fiori rossi con probabilità $p = 0.6$ e fiori bianchi con probabilità $(1 - p) = 0.4$. Calcolare le probabilità che, su 5 fiori:

- (1) 3 fiori siano rossi
- (2) 3 fiori siano bianchi
- (3) non più di 4 fiori siano rossi
- (4) non più di 4 fiori siano bianchi
- (5) almeno 3 fiori siano bianchi
- (6) almeno 3 fiori siano rossi

□

ESERCIZIO 4.14. In un test ci sono 10 domande con 4 risposte possibili per ciascuna, di cui 1 sola corretta. Se uno studente risponde a caso a tutte le domande, con quale probabilità almeno 6 di queste risultano corrette? □

ESERCIZIO 4.15. Un sistema satellitare è composto da 4 componenti e può funzionare adeguatamente se almeno 2 dei 4 componenti sono funzionanti. Se ogni componente è, indipendentemente, funzionante con probabilità 0.6, qual è la probabilità che il sistema funzioni adeguatamente? □

ESERCIZIO 4.16. Un canale di comunicazione trasmette dei bit 0 e 1. Tuttavia, a causa di rumore elettrostatico, la cifra trasmessa viene ricevuta in modo errato con probabilità 0.2. Supponiamo di voler trasmettere un messaggio importante costituito da una cifra binaria. Per ridurre la possibilità di errore, trasmettiamo 00000 invece di 0 e 11111 invece di 1. Se il destinatario del messaggio utilizza la decodifica "a maggioranza", qual è la

probabilità che il messaggio venga decodificato in modo errato? Si supponga che gli errori avvengano in modo indipendente. (Per decodifica “a maggioranza” si intende che il messaggio viene decodificato come “0” se ci sono almeno tre 0 nel messaggio ricevuto e come “1” in caso contrario.) \square

ESERCIZIO 4.17. Almeno la metà dei motori di un aeroplano è necessaria affinché questo funzioni. Supponiamo che ogni motore indipendentemente dagli altri funzioni con probabilità p . Per quali valori di p un aereo a 4 motori ha più probabilità di funzionare rispetto a un aereo a 2 motori? \square

ESERCIZIO 4.18. Samuel Pepys ha scritto una lettera ad Isaac Newton per chiedergli quale di questi tre eventi sia più probabile:

- (1) che si ottenga almeno un 6 nel lancio di 6 dadi;
- (2) che si ottengano almeno due 6 nel lancio di 12 dadi;
- (3) che si ottengano almeno tre 6 nel lancio di 18 dadi.

Qual è stata la risposta di Newton? \square




FIGURA 4.4. A sinistra: Sir Isaac Newton (1642-1726).^a Uno dei più grandi scienziati di tutti i tempi. A destra: Samuel Pepys (1633-1703).^b È stato un politico inglese.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Portrait_of_Sir_Isaac_Newton,_1689.jpg

^bFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Samuel_Pepys_by_Sir_Godfrey_Kneller_1689.jpg

4.2.1. La scimmia instancabile di Borel. Il seguente esempio è un esperimento mentale che viene spesso presentato come un paradosso, poiché è un risultato controintuitivo. Non è tuttavia un paradosso dal punto di vista della matematica in quanto non porta ad alcuna contraddizione logica.

TEOREMA 4.19. *Si consideri una scimmia posta davanti a una macchina da scrivere che scrive sequenze di caratteri casuali. In un tempo infinito, la scimmia scriverà l'intera Divina Commedia di Dante Alighieri con probabilità 100%!*

L'esperimento è stato enunciato come un teorema, anche se occorrerebbe un enunciato più rigoroso. Per formulare più rigorosamente il problema, consideriamo l'insieme dei caratteri di una macchina da scrivere costituito da tutte le lettere minuscole, maiuscole, e i segni di punteggiatura

$$\text{Char} = \{a, b, c, \dots, x, y, z, A, B, C, \dots, X, Y, Z, ., !, ?, \dots\}$$

Il numero preciso dei caratteri di Char non è rilevante. Supponiamo che sia costituito da $n = \#\text{Char} = 66$ caratteri. Consideriamo il primo canto dell'*Inferno* della *Divina Commedia* di Dante Alighieri. È costituito da una sequenza di $k = 4842$ caratteri. Per descrivere tutte le possibili composizioni di 4842 caratteri che possono essere scritte casualmente dalla scimmia, consideriamo lo spazio degli eventi elementari

$$\Omega = \{(c_1, \dots, c_k) : c_i \in \text{Char}\}.$$

Ogni sequenza di caratteri (c_1, \dots, c_k) corrisponde a una composizione della scimmia (tantissime non hanno senso!). Ogni sequenza di caratteri è una disposizione, con possibili ripetizioni, di k elementi scelti da un insieme di n elementi. Quindi il numero delle possibili composizioni è $\#\Omega = 66^{4842}$. Il primo canto della *Divina Commedia* è una particolare sequenza, quella che fa così:

$$(N, e, l, ., m, e, z, z, o, \dots, d, i, e, t, r, o).$$

Supponendo le composizioni della scimmia siano equiprobabili, la probabilità che la scimmia in un tentativo scriva il primo canto della *Divina Commedia* è data da

$$p = \frac{1}{66^{4842}}.$$

Ovviamente questa probabilità è bassissima. Tuttavia è positiva, $p \in (0, 1)$. Se la scimmia ha a disposizione un tempo infinito, può fare N tentativi, dove N può essere un numero grande a piacere. La probabilità che in N tentativi la scimmia non scriva mai il primo canto della *Divina Commedia* è data da

$$(1 - p)^N.$$

Questo significa che la probabilità che in N tentativi la scimmia scriva il primo canto della *Divina Commedia* almeno una volta è data da

$$1 - (1 - p)^N.$$

Poiché non c'è un vincolo sul numero N , possiamo considerare il limite per $N \rightarrow +\infty$ (ovvero con un numero grandissimo di tentativi). Osserviamo che, poiché $p \in (0, 1)$, si ha $(1 - p) \in (0, 1)$. Quando questo numero viene moltiplicato per se stesso tante volte, diventa sempre più piccolo. Quindi

$$\lim_{N \rightarrow +\infty} \left(1 - (1 - p)^N\right) = 1 = 100\%. \quad (4.2)$$

Quindi la probabilità che in un numero infinito di tentativi la scimmia scriva almeno una volta il primo canto della *Divina Commedia* è il 100%.

Questo risultato è ovviamente molto controintuitivo. Inoltre l'esempio della scimmia serve solo a ricordare l'enunciato e l'esperimento funziona con qualunque evento di probabilità positiva. Quello che stabilisce il teorema è che, in un numero molto grande di tentativi, la probabilità che si verifichi almeno una volta un evento con probabilità positiva è del 100%.

Il teorema fa riflettere su come noi siamo poco capaci di percepire l'infinito. Per avere un'idea, svolgiamo il seguente conto per avere un'idea degli ordini di grandezza. Il limite (4.2) stabilisce che (per la definizione di limite) per ogni $\varepsilon > 0$ esiste $M = M(\varepsilon)$ tale che per $N \geq M$ si ha

$$1 - (1 - p)^N > 1 - \varepsilon.$$

Fissiamo, ad esempio, $\varepsilon = 1\% = 0.01$. In corrispondenza di questa soglia, esiste $M = M(\varepsilon)$ tale che per $N \geq M$ si ha

$$1 - (1 - p)^N > 99\%.$$

Ovvero, se si fanno abbastanza tentativi ($N \geq M$), la probabilità che venga scritto almeno una volta il primo canto della *Divina Commedia* è almeno il 99%. Cerchiamo di capire quanto è grande questa soglia M . Poiché il logaritmo è strettamente crescente e $\log_{10}(1 - p) < 0$

$$\begin{aligned} 1 - (1 - p)^M > 1 - 0.01 &\iff (1 - p)^M < 0.01 = \cdot 10^{-2} \\ &\iff M \log_{10}(1 - p) < -2 \\ &\iff M |\log_{10}(1 - p)| > 2 \\ &\iff M > \frac{2}{|\log_{10}(1 - p)|} \end{aligned}$$

Capiamo qual è l'ordine di grandezza di $|\log_{10}(1 - p)|$. Osserviamo che per la concavità del logaritmo, per ogni $x \in (-\frac{1}{2}, 0)$ si ha che

$$2x < \ln(1 + x).$$

In particolare otteniamo che

$$|\log_{10}(1 - p)| = -\log_{10}(1 - p) = -\frac{1}{\ln(10)} \ln(1 - p) \leq \frac{1}{\ln(10)} 2p,$$

da cui

$$\frac{2}{|\log_{10}(1 - p)|} \geq \frac{2 \ln(10)}{2p} = \ln(10) 66^{4842}.$$

Facciamo una stima molto grossolana: $\ln(10) 66^{4842} > 10^{4842}$. Concludiamo che, per avere probabilità di almeno 99%, almeno $M > 10^{4842}$. Per renderci conto di quanto è grande questo numero, contiamo i secondi trascorsi dal Big Bang. Il nostro universo ha circa 13.8 miliardi di anni. Abbondiamo anche con 14, cioè $14 \cdot 10^9$ anni. Ogni anno ha 365 giorni (abbondiamo anche con 366!), ogni giorno ha 24 ore, ogni ora 60 minuti e ogni minuto 60 secondi. Sono trascorsi meno di

$$14 \cdot 10^9 \cdot 366 \cdot 24 \cdot 60 \cdot 60 = 442713600 \cdot 10^9 < 10^{18}$$

secondi dal Big Bang. Osserviamo la differenza di ordine di grandezza tra 10^{4842} e 10^{18} !!!

Ford e Arthur si ritrovarono in una piccola e luminosa cabina rosa shocking.

Ford era eccitatissimo.

“Arthur!” gridò. “È fantastico! Siamo stati raccolti da un’astronave con un Motore ad Improbabilità Infinita! È incredibile! Ne avevo già sentito parlare, ma la notizia è sempre stata smentita! Evidentemente invece ce l’hanno fatta! Hanno creato un Motore ad Improbabilità Infinita! Arthur, hai sentito, è... Arthur? Che succede?”

Arthur era spiacciato contro la porta della cabina nel tentativo di non farla aprire, ma non funzionava. Attraverso le fessure si vedevano piccole mani pelose, con le dita macchiate d’inchiostro, che cercavano di insinuarsi dentro. Voci stridule ciarlavano senza senso.

Arthur alzò gli occhi.

“Ford!” disse. “Qui fuori c’è un’incredibile moltitudine di scimmie che vogliono parlarci di una sceneggiatura dell’Amleto che avrebbero appena finito di scrivere!”

D. Adams, *Guida galattica per gli autostoppisti*

4.3. Legge di Poisson

La legge di Poisson descrive il numero di successi in tanti tentativi indipendenti quando la probabilità di un singolo successo è bassa (nel regime in cui la media dei successi è costante). Per rendere rigorosa questa affermazione, enunciamo e dimostriamo il seguente risultato.

TEOREMA 4.20. *Sia $n \in \mathbb{N}$, $n \geq 1$, sia $\lambda > 0$ e sia $p_n = \frac{\lambda}{n}$. Consideriamo una successione di variabili aleatorie X_n distribuite con legge binomiale $X_n \sim B(n, p_n)$. Allora*

$$\lim_{n \rightarrow +\infty} \mathbb{P}(\{X_n = k\}) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \text{per ogni } k \in \mathbb{N}.$$

DIMOSTRAZIONE. Dalla definizione di legge binomiale si ha che

$$\begin{aligned} \mathbb{P}(\{X_n = k\}) &= \binom{n}{k} p_n^k (1 - p_n)^{n-k} = \frac{n!}{k!(n-k)!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} \\ &= \frac{\lambda^k}{k!} \underbrace{\frac{n}{n} \cdot \frac{n-1}{n} \cdots \frac{n-k+1}{n}}_{k \text{ termini}} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-k} \\ &\xrightarrow{n \rightarrow +\infty} \frac{\lambda^k}{k!} e^{-\lambda}, \end{aligned}$$

dove abbiamo usato che

$$\begin{aligned} \lim_{n \rightarrow +\infty} \frac{n-i}{n} &= 1, \\ \lim_{n \rightarrow +\infty} \left(1 - \frac{\lambda}{n}\right)^n &= \lim_{n \rightarrow +\infty} \left(1 - \frac{\lambda}{n}\right)^{\frac{n}{\lambda} \lambda} = e^{-\lambda} \end{aligned}$$

per il limite notevole $\lim_{x \rightarrow 0} (1+x)^{\frac{1}{x}} = e$,

$$\lim_{n \rightarrow +\infty} \left(1 - \frac{\lambda}{n}\right)^{-k} = 1.$$

□

DEFINIZIONE 4.21. (Legge di Poisson) Sia $\lambda \in (0, +\infty)$. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ si dice *distribuita con legge di Poisson con parametro λ* se ha range $R(X) = \mathbb{N}$ e

$$\mathbb{P}(\{X = k\}) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \text{per } k \in \mathbb{N}.$$

□



FIGURA 4.5. Siméon-Denis Poisson (1781-1840).^a Dà il nome alla legge di Poisson. Ha ottenuto importanti risultati in fisica (si pensi all'equazione di Poisson in elettrostatica).

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Simeon_Poisson.jpg

OSSERVAZIONE 4.22. È facile ricordare la formula per la legge di Poisson: è data dai termini della serie di Taylor dell'esponenziale:

$$e^\lambda = \sum_{k=0}^{+\infty} \frac{\lambda^k}{k!}.$$

Ricordiamo che la serie scritta nella formula sopra converge per ogni $\lambda \in \mathbb{R}$ (in realtà a noi interessa solo $\lambda > 0$). Questa osservazione che fornisce un'ulteriore spiegazione alla presenza del fattore $e^{-\lambda}$, necessaria per far sì che

$$\sum_{k=0}^{+\infty} \mathbb{P}(\{X = k\}) = 1.$$

□




FIGURA 4.6. *xkcd* 2605. TAYLOR SERIES. Credits: <https://xkcd.com/2605/>

■ Link a slide animata in cui viene mostrata la convergenza della funzione di massa di probabilità della legge binomiale alla legge di Poisson: <https://orlandopoliba.github.io/Manim-ProbStatPoliBA/Poisson/Poisson.html>

In Figura 4.7 si può vedere un esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge di Poisson.




FIGURA 4.7. Esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge di Poisson.

</> Link a grafico interattivo in cui si può studiare l'aspetto della funzione di massa di probabilità della legge di Poisson al variare di λ : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/poisson.html

PROPOSIZIONE 4.23. *Siano $X \sim P(\lambda)$ e $Y \sim P(\mu)$ indipendenti. Allora $X + Y \sim P(\lambda + \mu)$.*

DIMOSTRAZIONE. Calcoliamo per $k \in \mathbb{N}$

$$\begin{aligned}
 \mathbb{P}(\{X + Y = k\}) & \quad \blacksquare \text{ decomponendo } k \\
 &= \mathbb{P}\left(\bigcup_{h=0}^k \{X = h\} \cap \{Y = k - h\}\right) \quad \blacksquare \text{ eventi disgiunti} \\
 &= \sum_{h=0}^k \mathbb{P}(\{X = h\} \cap \{Y = k - h\}) \quad \blacksquare \text{ indipendenza} \\
 &= \sum_{h=0}^k \mathbb{P}(\{X = h\})\mathbb{P}(\{Y = k - h\}) \quad \blacksquare \text{ legge di Poisson} \\
 &= \sum_{h=0}^k e^{-\lambda} \frac{\lambda^h}{h!} e^{-\mu} \frac{\mu^{k-h}}{(k-h)!} \quad \blacksquare \times \frac{k!}{k!} \\
 &= e^{-(\lambda+\mu)} \frac{1}{k!} \sum_{h=0}^k \binom{k}{h} \lambda^h \mu^{k-h} \quad \blacksquare \text{ binomio di Newton} \\
 &= e^{-(\lambda+\mu)} \frac{(\lambda + \mu)^k}{k!}.
 \end{aligned}$$

Questo conclude la dimostrazione. □

PROPOSIZIONE 4.24. *Sia $X \sim P(\lambda)$. Allora*

$$\mathbb{E}(X) = \lambda.$$

DIMOSTRAZIONE. Calcoliamo

$$\begin{aligned}
 \mathbb{E}(X) &= \sum_{k=0}^{+\infty} k \mathbb{P}(\{X = k\}) = \sum_{k=0}^{+\infty} k e^{-\lambda} \frac{\lambda^k}{k!} = \sum_{k=1}^{+\infty} k e^{-\lambda} \frac{\lambda^k}{k!} \\
 &= \sum_{k=1}^{+\infty} e^{-\lambda} \frac{\lambda^k}{(k-1)!} = \lambda \sum_{k=1}^{+\infty} e^{-\lambda} \frac{\lambda^{k-1}}{(k-1)!} = \lambda \sum_{k=0}^{+\infty} e^{-\lambda} \frac{\lambda^k}{k!} = \lambda.
 \end{aligned}$$

Questo conclude la dimostrazione. □

PROPOSIZIONE 4.25. *Sia $X \sim P(\lambda)$. Allora*

$$\text{Var}(X) = \lambda.$$

DIMOSTRAZIONE. Usiamo la formula per la varianza (3.1) per ottenere (attenzione a spezzare la serie nella somma!)

$$\begin{aligned}
 \text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \sum_{k=0}^{+\infty} k^2 \mathbb{P}(\{X = k\}) - \lambda^2 = \sum_{k=1}^{+\infty} k^2 e^{-\lambda} \frac{\lambda^k}{k!} - \lambda^2 \\
 &= \sum_{k=1}^{+\infty} k(k-1) e^{-\lambda} \frac{\lambda^k}{k!} + \sum_{k=1}^{+\infty} k e^{-\lambda} \frac{\lambda^k}{k!} - \lambda^2 \\
 &= \sum_{k=2}^{+\infty} k(k-1) e^{-\lambda} \frac{\lambda^k}{k!} + \mathbb{E}(X) - \lambda^2 \\
 &= \sum_{k=2}^{+\infty} e^{-\lambda} \frac{\lambda^k}{(k-2)!} + \lambda - \lambda^2 \\
 &= \lambda^2 \sum_{k=2}^{+\infty} e^{-\lambda} \frac{\lambda^{k-2}}{(k-2)!} + \lambda - \lambda^2 = \lambda^2 \sum_{k=0}^{+\infty} e^{-\lambda} \frac{\lambda^k}{k!} + \lambda - \lambda^2 \\
 &= \lambda^2 + \lambda - \lambda^2 = \lambda.
 \end{aligned}$$

Questo conclude la dimostrazione. \square

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 4.26. Supponiamo che il numero medio di incidenti che si verificano settimanalmente su un particolare tratto di autostrada sia 3. Calcolare la probabilità che si verifichi almeno un incidente questa settimana. \square

ESERCIZIO 4.27. Se il numero medio di sinistri gestiti giornalmente da una compagnia di assicurazioni è 5, qual è la probabilità che in un giorno ci siano meno di 3 sinistri? Qual è la probabilità che ci siano esattamente 4 reclami in ciascuno di 3 dei prossimi 5 giorni? Si supponga che il numero di reclami in giorni diversi sia indipendente. \square

ESERCIZIO 4.28. Si consideri un esperimento che consiste nel contare il numero di particelle α emesse in un intervallo di 1 secondo da 1 grammo di materiale radioattivo. Se sappiamo dall'esperienza passata che, in media, vengono emesse 3.2 di tali particelle α , qual è una buona approssimazione della probabilità che non vengano emesse più di 2 particelle α ? \square

ESERCIZIO 4.29. È stato stabilito che il numero di stereo difettosi prodotti giornalmente in un determinato impianto è distribuito con una legge di Poisson con parametro 4. In un arco di 2 giorni, qual è la probabilità che il numero di stereo difettosi non superi 3? \square

ESERCIZIO 4.30. Se acquisti 50 biglietti della lotteria, per ognuno dei quali la probabilità di vincere 1 un premio è $\frac{1}{100}$, qual è la probabilità di vincere un premio (a) almeno una volta, (b) esattamente una volta e (c) almeno due volte? Calcolare le probabilità utilizzando la legge binomiale e la legge di Poisson e confrontarle. \square

ESERCIZIO 4.31. Il numero di volte in cui una persona contrae un raffreddore in un anno è una variabile casuale di Poisson con parametro $\lambda = 3$. Supponiamo che sia stato appena commercializzato un nuovo farmaco miracoloso (basato su grandi quantità di vitamina C) che riduca il parametro di Poisson a $\lambda = 2$ per il 75% della popolazione. Per l'altro 25% della popolazione, il farmaco non ha effetti apprezzabili sul raffreddore. Se una persona prova il farmaco per un anno e ha 0 raffreddori in quel periodo, quanto è probabile che il farmaco sia benefico per lui o lei? \square

ESERCIZIO 4.32. La probabilità di errore nella trasmissione di una cifra binaria in un canale di comunicazione è $1/10^3$. Scrivi un'espressione per la probabilità esatta di più di 3 errori durante la trasmissione di un blocco di 10^3 bit. Qual è il suo valore approssimativo? Assumere indipendenza. \square

4.4. Legge geometrica

Prima di iniziare la discussione di questo capitolo, è utile ricordare la somma della serie geometrica, che dà il nome a questa legge.

PROPOSIZIONE 4.33. *Sia $q > 0$. Allora*

$$\sum_{k=0}^N q^k = \frac{1 - q^{N+1}}{1 - q}.$$

In particolare, se $q \in (0, 1)$, allora la serie geometrica di ragione q è convergente e

$$\sum_{k=0}^{+\infty} q^k = \frac{1}{1 - q}.$$

DIMOSTRAZIONE. Definiamo

$$s_N = \sum_{k=0}^N q^k = 1 + q + q^2 + \cdots + q^N.$$

Osserviamo che

$$qs_N = q + q^2 + \cdots + q^{N+1}.$$

Sottraendo le due equazioni, otteniamo che

$$(1 - q)s_N = 1 - q^{N+1}$$

da cui

$$s_N = \frac{1 - q^{N+1}}{1 - q}.$$

Poiché $q \in (0, 1)$, $q^{N+1} \rightarrow 0$ per $N \rightarrow +\infty$. Segue che

$$s_N \rightarrow \frac{1}{1 - q}, \text{ per } N \rightarrow +\infty,$$

da cui la tesi. \square

La legge geometrica descrive il primo successo in una sequenza di tentativi indipendenti.

DEFINIZIONE 4.34. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ è distribuita con legge geometrica se ha range $R(X) = \mathbb{N} \setminus \{0\} = \{1, 2, 3, \dots\}$ e

$$\mathbb{P}(\{X = k\}) = (1 - p)^{k-1}p, \quad \text{per } k = 1, 2, 3, \dots$$

□

■ Link a slide animata in cui vengono mostrati molti esperimenti per un fenomeno descritto dalla legge geometrica: <https://orlandopoliba.github.io/Manim-ProbStatPoliba/Geometric/Geometric.html>

In Figura 4.8 si può vedere un esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge geometrica.




FIGURA 4.8. Esempio di funzione di massa di probabilità di una variabile aleatoria distribuita con legge geometrica.

↔ Link a grafico interattivo in cui si può studiare l'aspetto della funzione di massa di probabilità della legge geometrica al variare di p : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/geometric.html

OSSERVAZIONE 4.35. Data $X \sim \text{Geo}(p)$, è semplice calcolare le probabilità dei seguenti eventi:

$$\mathbb{P}(\{X > n\}) = (1 - p)^n, \quad \text{per } n \in \mathbb{N}.$$

L'idea di questa formula è semplice: la probabilità che il primo successo avvenga dall' $(n + 1)$ -esimo tentativo in poi è uguale alla probabilità di avere solamente insuccessi nei primi n tentativi. Per ricavare rigorosamente la formula, utilizziamo la somma della serie

geometrica ottenuta nella Proposizione 4.33:

$$\begin{aligned}
\mathbb{P}(\{X > n\}) &= \sum_{k=n+1}^{+\infty} \mathbb{P}(\{X = k\}) \\
&= \sum_{k=n+1}^{+\infty} (1-p)^{k-1} p \quad \blacktriangleleft \text{cambio di indice } h = k - n - 1 \\
&= p \sum_{h=0}^{+\infty} (1-p)^{h+n} \\
&= p(1-p)^n \sum_{h=0}^{+\infty} (1-p)^h \quad \blacktriangleleft \text{somma della serie geometrica} \\
&= p(1-p)^n \frac{1}{1-(1-p)} = (1-p)^n.
\end{aligned}$$

□

La legge geometrica gode della proprietà di assenza di memoria.

PROPOSIZIONE 4.36. *Sia $X \sim \text{Geo}(p)$. Allora per ogni $m, n \in \mathbb{N}$ si ha che*

$$\mathbb{P}(\{X > m+n\} | \{X > m\}) = \mathbb{P}(\{X > n\}).$$

DIMOSTRAZIONE. Calcoliamo, utilizzando la formula ottenuta nell'Osservazione 4.35,

$$\begin{aligned}
\mathbb{P}(\{X > m+n\} | \{X > m\}) &= \frac{\mathbb{P}(\{X > m+n\} \cap \{X > m\})}{\mathbb{P}(\{X > m\})} \\
&= \frac{\mathbb{P}(\{X > m+n\})}{\mathbb{P}(\{X > m\})} = \frac{(1-p)^{m+n}}{(1-p)^m} \\
&= (1-p)^n = \mathbb{P}(\{X > n\}).
\end{aligned}$$

Questo conclude la dimostrazione. □

OSSERVAZIONE 4.37. \blacktriangleleft Si può dimostrare che la legge geometrica è l'unica legge di variabili aleatorie con range in $\mathbb{N} \setminus \{0\}$ che gode della proprietà di assenza di memoria. Infatti, sia $X: \Omega \rightarrow \mathbb{R}$ una variabile aleatoria con range $R(X) = \mathbb{N} \setminus \{0\}$ che gode di assenza di memoria, ma di cui non conosciamo la legge. Per la proprietà di assenza di memoria si ha che

$$\mathbb{P}(\{X > m+n\} | \{X > m\}) = \mathbb{P}(\{X > n\})$$

per ogni $m, n \in \mathbb{N}$. Questo vuol dire che

$$\begin{aligned}
\frac{\mathbb{P}(\{X > m+n\})}{\mathbb{P}(\{X > m\})} &= \mathbb{P}(\{X > n\}) \\
\implies \mathbb{P}(\{X > m+n\}) &= \mathbb{P}(\{X > m\})\mathbb{P}(\{X > n\}).
\end{aligned}$$

Scegliendo $n = 1$ e ponendo $p = \mathbb{P}(\{X = 0\})$, si ha che

$$\begin{aligned}
\mathbb{P}(\{X > m+1\}) &= \mathbb{P}(\{X > m\})\mathbb{P}(\{X > 1\}) \\
&= \mathbb{P}(\{X > m\})(1 - \mathbb{P}(\{X = 0\})) = \mathbb{P}(\{X > m\})(1-p).
\end{aligned}$$

Abbiamo quindi una formula iterativa

$$\begin{cases} \mathbb{P}(\{X > 0\}) = 1, & \text{(poiché } R(X) = \mathbb{N} \setminus \{0\}\text{),} \\ \mathbb{P}(\{X > m + 1\}) = (1 - p)\mathbb{P}(\{X > m\}) & \text{per } m \in \mathbb{N}, \end{cases}$$

Applicando il principio di induzione, deduciamo che

$$\mathbb{P}(\{X > m\}) = (1 - p)^m \quad \text{per } m \in \mathbb{N}.$$

Da questa formula concludiamo che per $k = 1, 2, 3, \dots$,

$$\begin{aligned} \mathbb{P}(\{X = k\}) &= \mathbb{P}(\{X \geq k\}) - \mathbb{P}(\{X \geq k + 1\}) \\ &= \mathbb{P}(\{X > k - 1\}) - \mathbb{P}(\{X > k\}) = (1 - p)^{k-1} - (1 - p)^k \\ &= (1 - p)^{k-1}(1 - 1 + p) = (1 - p)^{k-1}p. \end{aligned}$$

Quindi $X \sim \text{Geo}(p)$. □

PROPOSIZIONE 4.38. *Sia $X \sim \text{Geo}(p)$. Allora*

$$\mathbb{E}(X) = \frac{1}{p}.$$

DIMOSTRAZIONE. Calcoliamo

$$\mathbb{E}(X) = \sum_{k=1}^{+\infty} k(1 - p)^{k-1}p = p \sum_{k=1}^{+\infty} \frac{d}{dp} \left(- (1 - p)^k \right).$$

Per farlo, definiamo¹

$$s_N = p \sum_{k=1}^N \frac{d}{dp} \left(- (1 - p)^k \right).$$

Per la somma geometrica ottenuta in Proposizione 4.33 otteniamo che

$$\begin{aligned} s_N &= p \frac{d}{dp} \left(- \sum_{k=1}^N (1 - p)^k \right) = p \frac{d}{dp} \left(- (1 - p) \sum_{k=0}^{N-1} (1 - p)^k \right) \\ &= p \frac{d}{dp} \left(- (1 - p) \frac{1 - (1 - p)^N}{1 - (1 - p)} \right) = p \frac{d}{dp} \left(\frac{(1 - p)^{N+1} - 1 + p}{p} \right) \\ &= p \left(\frac{(N + 1)(1 - p)^N + 1}{p} - \frac{(1 - p)^{N+1} - 1 + p}{p^2} \right) \\ &= \frac{p(N + 1)(1 - p)^N + p - (1 - p)^{N+1} + 1 - p}{p} \rightarrow \frac{1}{p} \end{aligned}$$

per $N \rightarrow +\infty$, dove abbiamo usato che $(N + 1)(1 - p)^N \rightarrow 0$. □

PROPOSIZIONE 4.39. *Sia $X \sim \text{Geo}(p)$. Allora*

$$\text{Var}(X) = \frac{1 - p}{p^2}.$$

¹Questi passaggi si possono bypassare ricordando il teorema della derivazione delle serie di potenze!

DIMOSTRAZIONE. Utilizziamo direttamente il teorema della derivazione di serie di potenze:

$$\begin{aligned}
 \text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \sum_{k=1}^{+\infty} k^2(1-p)^{k-1}p - \frac{1}{p^2} \\
 &= p \sum_{k=1}^{+\infty} \frac{d}{dp} \left(-k(1-p)^k \right) - \frac{1}{p^2} = p \frac{d}{dp} \left(-\frac{1-p}{p} \sum_{k=1}^{+\infty} k(1-p)^{k-1}p \right) - \frac{1}{p^2} \\
 &= p \frac{d}{dp} \left(-\frac{1-p}{p} \mathbb{E}(X) \right) - \frac{1}{p^2} = p \frac{d}{dp} \left(\frac{p-1}{p^2} \right) - \frac{1}{p^2} \\
 &= p \left(\frac{1}{p^2} - 2 \frac{p-1}{p^3} \right) - \frac{1}{p^2} = \frac{2-p}{p^2} - \frac{1}{p^2} = \frac{1-p}{p^2}.
 \end{aligned}$$

□

OSSERVAZIONE 4.40. (Paradosso di San Pietroburgo) Daniel Bernoulli propone il seguente gioco d'azzardo nei *Commentarii Academiae Scientiarum Imperialis Petropolitanae* nel 1738.



FIGURA 4.9. Daniel Bernoulli (1700-1782).^a Un altro membro della famiglia Bernoulli (nipote di Jakob). Viene ricordato principalmente per i contributi alla fluidodinamica, ma ha ottenuto risultati importanti nella statistica e nella teoria del rischio.

^aFonte dell'immagine: [https://commons.wikimedia.org/wiki/File:ETH-BIB-Bernoulli,_Daniel_\(1700-1782\)-Portrait-Portr_10971.tif_\(cropped\).jpg](https://commons.wikimedia.org/wiki/File:ETH-BIB-Bernoulli,_Daniel_(1700-1782)-Portrait-Portr_10971.tif_(cropped).jpg)

Un giocatore deve pagare una certa somma per partecipare al gioco. Viene lanciata una moneta equilibrata fino a quando non esce testa. Se esce testa al primo lancio, il giocatore vince 2 unità di denaro. Se esce testa al secondo lancio, il giocatore vince 4 unità di denaro. Se esce testa al terzo lancio, il giocatore vince 8 unità di denaro, e così via. Il giocatore vince 2^k unità di denaro se esce testa al k -esimo lancio.

La domanda è: quanto sarebbe disposto a pagare il giocatore per partecipare al gioco?

Per rispondere alla domanda con la teoria della probabilità, calcoliamo la vincita attesa del giocatore. Per descrivere il gioco consideriamo la variabile aleatoria

$$X = \text{“primo lancio in cui esce testa”} \sim \text{Geo}\left(\frac{1}{2}\right).$$

La vincita del giocatore è la variabile aleatoria

$$Y = 2^X.$$

Calcoliamo la vincita attesa del giocatore utilizzando la Proposizione 3.38.

$$\mathbb{E}(Y) = \mathbb{E}(2^X) = \sum_{k=1}^{+\infty} 2^k \mathbb{P}(\{X = k\}) = \sum_{k=1}^{+\infty} 2^k \left(\frac{1}{2}\right)^{k-1} \frac{1}{2} = \sum_{k=1}^{+\infty} 1 = +\infty.$$

In altre parole, la vincita attesa del giocatore è infinito. Quindi, il giocatore dovrebbe essere disposto a pagare una somma infinita per partecipare al gioco. Infatti pagando una quota x per partecipare al gioco, il giocatore può giocare tante volte quante vuole, e potrà capitare la volta in cui vincerà 2^k unità di denaro, con k molto grande (evento con probabilità molto bassa).

Tuttavia, nessuna persona ragionevole (e con una disponibilità di denaro finita) sarebbe disposta a pagare una somma grande per partecipare a questo gioco d'azzardo.

Bernoulli utilizza questo paradosso per mostrare che le decisioni non sono sempre guidate dal guadagno atteso, ma piuttosto da una funzione di utilità. Citando Bernoulli: “Non c'è dubbio che un guadagno di mille ducati ha più valore per un povero che per un ricco, sebbene entrambi abbiano la stessa somma.” \square

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 4.41. Trovare la probabilità che nei lanci successivi di un dado equilibrato, al quinto lancio esca per la prima volta un 3. \square

ESERCIZIO 4.42. Un paziente è in attesa di un donatore di rene adatto per un trapianto. Se la probabilità che un donatore selezionato casualmente sia compatibile è $p = 0.1$. a) Qual è la probabilità che il donatore compatibile sia trovato dal sesto testato in poi sapendo che i primi tre testati non erano compatibili? b) Qual è in media il numero previsto di donatori che verranno testati prima che venga trovato un donatore compatibile? \square

ESERCIZIO 4.43. Un'azienda controlla le recensioni dei suoi clienti, facendo caso ogni settimana alla prima recensione negativa ricevuta. Si rende conto che, in media, la prima recensione negativa ricevuta in una settimana è la decima. Con che probabilità un cliente scrive una recensione negativa? \square

ESERCIZIO 4.44. Bob ha deciso di non studiare il programma di Probabilità ma di provare a passare l'esame comunque. Ad ogni appello ha il 10% di probabilità di passare l'esame (indipendentemente dalle prove svolte precedentemente). Prova e riprova l'esame finché non lo passa.

- (1) Qual è la probabilità che passi l'esame entro il terzo appello?
- (2) Entro quale appello può passare l'esame almeno con il 50% di probabilità?

□

ESERCIZIO 4.45. Vuoi provare a vincere un terno secco a Lotto. Decidi di puntare 1,00€ per giocare 3 numeri sulla ruota di Bari (ad es.: 1, 45 e 90) scegliendo di puntare su un terno. Se tra i 5 numeri estratti escono i 3 scelti, vinci 4.500,00€, altrimenti non vinci niente. 1) Calcolare la probabilità p di vincere se giochi una volta. 2) Hai giocato i tuoi numeri sei volte e non sono usciti. Sapendo che si è verificato questo evento, qual è la probabilità che alla prossima giocata escano i tuoi numeri? 3) Provi e riprovi a giocare finché finalmente non vinci. Qual è la tua vincita media? □

ESERCIZIO 4.46. In delle scatole di cereali si possono trovare dei coupon, numerati da 1 a 5. Sono necessari tutti per completare il set da collezione. In una scatola si trova un solo coupon. Quante scatole in media bisogna aprire per completare la collezione? □

ESERCIZIO 4.47. Tre pistoleri A, B, C si sfidano in un triello. Tutti sanno che:

- A colpisce con il 30% di probabilità;
- B non sbaglia mai un colpo;
- C colpisce con il 50% di probabilità.

Quando uno dei tre viene colpito, muore. I tre sparano uno alla volta ciclicamente (seguendo l'ordine $A - B - C$ tra chi è rimasto vivo), scegliendo chi sparare, finché non ne rimane uno vivo. Il pistolero A inizia a sparare. Qual è la strategia migliore per A ? □

ESERCIZIO 4.48. 'Craps' è un gioco del casino. Regole: si lanciano 2 dadi. Il giocatore vince se la somma del suo primo lancio è 7 o 11, perde se è 2,3, o 12. Ogni altro esito viene nominato 'punto'. Se il risultato del primo lancio è un 'punto', il giocatore lancia i due dadi ripetutamente finché esce il suo 'punto' (in tal caso vince) o 7 (in tal caso perde). Qual è la probabilità di vincere? □

CAPITOLO 5

Leggi continue

Contenuti

5.1. Legge uniforme	129
Esercizi	130
5.2. Legge normale	131
Esercizi	136
5.3. Legge esponenziale	137
Esercizi	140
5.4. Legge Gamma	141
5.5. Legge chi-quadro	146
5.6. Legge t-Student	147

In questo capitolo descriviamo alcune leggi continue.

5.1. Legge uniforme

DEFINIZIONE 5.1. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ è distribuita con *legge uniforme* in un intervallo $[a, b]$ se ha funzione di densità di probabilità

$$f_X(x) = \begin{cases} \frac{1}{b-a}, & \text{se } a < x < b, \\ 0, & \text{altrimenti.} \end{cases}$$

Scriveremo $X \sim U(a, b)$. Si veda la Figura 5.1. □




FIGURA 5.1. Densità di una variabile aleatoria $X \sim U(a, b)$.

OSSERVAZIONE 5.2. La funzione di distribuzione cumulativa di una variabile aleatoria $X \sim U(a, b)$ è data da

$$F_X(x) = \mathbb{P}(\{X \leq x\}) = \int_{-\infty}^x f_X(t) dt.$$

Per $x < a$ si ha che $F_X(x) = 0$. Per $x \in [a, b]$ si ha che

$$F_X(x) = \mathbb{P}(\{X \leq x\}) = \int_a^x \frac{1}{b-a} dt = \frac{x-a}{b-a}$$

e per $x > b$ si ha che $F_X(x) = 1$. □

PROPOSIZIONE 5.3. Sia $X \sim U(a, b)$. Allora $\mathbb{E}(X) = \frac{a+b}{2}$ e $\text{Var}(X) = \frac{(b-a)^2}{12}$.

DIMOSTRAZIONE. Calcoliamo

$$\begin{aligned} \mathbb{E}(X) &= \int_a^b x \frac{1}{b-a} dx = \frac{1}{b-a} \left[\frac{x^2}{2} \right]_{x=a}^{x=b} = \frac{1}{b-a} \frac{b^2 - a^2}{2} \\ &= \frac{(b-a)(b+a)}{2(b-a)} = \frac{a+b}{2}. \end{aligned}$$

Calcoliamo

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \int_a^b x^2 \frac{1}{b-a} dx - \frac{(a+b)^2}{4} \\ &= \frac{1}{b-a} \left[\frac{x^3}{3} \right]_{x=a}^{x=b} - \frac{a^2 + 2ab + b^2}{4} \\ &= \frac{b^3 - a^3}{3(b-a)} - \frac{a^2 + 2ab + b^2}{4} \\ &= \frac{b^2 + ab + a^2}{3} - \frac{a^2 + 2ab + b^2}{4} \\ &= \frac{4b^2 + 4ab + 4a^2 - 3a^2 - 6ab - 3b^2}{12} \\ &= \frac{b^2 - 2ab + a^2}{12} = \frac{(b-a)^2}{12}. \end{aligned}$$

□

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 5.4. Arrivi a una fermata dell'autobus alle 10 in punto, e sai che l'autobus arriverà ad un orario distribuito uniformemente tra le 10 e le 10:30. Qual è la probabilità che dovrai aspettare più di 10 minuti? Se alle 10:15 il bus non è ancora arrivato, qual è la probabilità che dovrai aspettare almeno altri 10 minuti? □

ESERCIZIO 5.5. Sia X la variabile aleatoria che indica la corrente in un sottile filo di rame misurata in milliampere. Si assuma che il range di X sia $[0, 20]$ e si assuma che X sia distribuita uniformemente. Qual è la probabilità che una misurazione della corrente sia compresa tra 5 e 10 milliampere? □

ESERCIZIO 5.6. Sia X un punto scelto sull'intervallo $[-2, 2]$ secondo una legge uniforme.

- (1) Calcolare la probabilità che il triangolo equilatero di lato $|X|$ abbia area maggiore di 1.
- (2) Calcolare il valore atteso dell'area del quadrato di lato $|X|$.

□

ESERCIZIO 5.7. ♣ Alice estrae un numero reale uniformemente nell'intervallo $[0, 1]$. Bob estrae allo stesso modo finché non ottiene un numero più grande di quello di Alice. Quante estrazioni si aspetta di fare? \square

5.2. Legge normale

Definiamo in questa sezione una delle variabili aleatorie più importanti. Prima di definire la densità della legge normale (o gaussiana), svolgiamo un conto.



FIGURA 5.2. Carl Friedrich Gauss (1777-1855).^a Non ha bisogno di presentazioni. Ha ottenuto tra i più importanti risultati in matematica. Ha utilizzato la legge normale per studiare il comportamento degli errori nelle misurazioni.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Carl_Friedrich_Gauss.jpg

PROPOSIZIONE 5.8. *Si ha che*

$$\int_{\mathbb{R}} e^{-\frac{1}{2}x^2} dx = \sqrt{2\pi}.$$

DIMOSTRAZIONE. Calcoliamo prima

$$\int_{\mathbb{R}} e^{-x^2} dx. \quad (5.1)$$

L'integrale nell'enunciato si otterrà con un cambio di variabile. L'integranda in (5.1) non ha una primitiva nota in termini delle funzioni elementari. Occorre adoperare un trucco per calcolare l'integrale. Osserviamo che è più semplice calcolare il quadrato dell'integrale, usando il Teorema di Fubini-Tonelli:

$$\left(\int_{\mathbb{R}} e^{-x^2} dx \right)^2 = \left(\int_{\mathbb{R}} e^{-x^2} dx \right) \left(\int_{\mathbb{R}} e^{-y^2} dy \right) = \iint_{\mathbb{R}^2} e^{-(x^2+y^2)} dx dy.$$

Il vantaggio è che $x^2 + y^2$ è la norma del vettore di due componenti (x, y) . Possiamo allora calcolare l'integrale in coordinate polari (ρ, θ) . Ricordiamo che si può parametrizzare il piano privato del semiasse delle ascisse $\mathbb{R}^2 \setminus ((0, +\infty) \times \{0\})$ usando la funzione

$$\Psi: (0, +\infty) \times (0, 2\pi) \rightarrow \mathbb{R}^2 \setminus ((0, +\infty) \times \{0\}), \quad \Psi(\rho, \theta) = (\rho \cos \theta, \rho \sin \theta).$$

Notiamo la relazione:

$$x^2 + y^2 = \rho^2(\cos^2 \theta + \sin^2 \theta) = \rho^2.$$

Cambiamo variabili nell'integrale doppio usando la funzione Ψ . Osserviamo che il semiasse delle ascisse $\mathbb{R}^2 \setminus ((0, +\infty) \times \{0\})$ è uni-dimensionale, quindi ha misura nulla. Ricordiamo che il fattore di correzione nell'integrale è dato dal determinante della matrice delle derivate di Ψ ,¹ quindi

$$\begin{aligned} \iint_{\mathbb{R}^2} e^{-(x^2+y^2)} dx dy &= \iint_{\mathbb{R}^2 \setminus ((0, +\infty) \times \{0\})} e^{-(x^2+y^2)} dx dy \\ &= \iint_{\Phi((0, +\infty) \times (0, 2\pi))} e^{-(x^2+y^2)} dx dy \\ &= \iint_{(0, +\infty) \times (0, 2\pi)} e^{-\rho^2} |\det(D\Psi(\rho, \theta))| d\rho d\theta. \end{aligned}$$

Calcoliamo la matrice delle derivate e il suo determinante:

$$D\Psi(\rho, \theta) = \begin{pmatrix} \frac{\partial \Psi_1}{\partial \rho} & \frac{\partial \Psi_2}{\partial \rho} \\ \frac{\partial \Psi_1}{\partial \theta} & \frac{\partial \Psi_2}{\partial \theta} \end{pmatrix} = \begin{pmatrix} \cos \theta & \sin \theta \\ -\rho \sin \theta & \rho \cos \theta \end{pmatrix},$$

$$\det(D\Psi(\rho, \theta)) = \rho \cos^2 \theta + \rho \sin^2 \theta = \rho.$$

Per il Teorema di Fubini-Tonelli segue che

$$\begin{aligned} \iint_{(0, +\infty) \times (0, 2\pi)} e^{-\rho^2} |\det(D\Psi(\rho, \theta))| d\rho d\theta &= \iint_{(0, +\infty) \times (0, 2\pi)} e^{-\rho^2} \rho d\rho d\theta \\ &= \int_0^{2\pi} \left(\int_0^{+\infty} e^{-\rho^2} \rho d\rho \right) d\theta = 2\pi \int_0^{+\infty} e^{-\rho^2} \rho d\rho \\ &= 2\pi \left[-\frac{1}{2} e^{-\rho^2} \right]_{\rho=0}^{\rho \rightarrow +\infty} = \pi. \end{aligned}$$

Quindi

$$\left(\int_{\mathbb{R}} e^{-x^2} dx \right)^2 = \pi \implies \int_{\mathbb{R}} e^{-x^2} dx = \sqrt{\pi}.$$

¹Se non si ricorda il cambio di variabili per integrali multipli, bisogna pensare al seguente ragionamento euristico: se consideriamo un quadratino di area molto piccola, la sua trasformazione tramite Ψ può essere approssimata dalla sua trasformazione tramite la matrice delle derivate $D\Psi$. Il numero che descrive come questa matrice cambia le aree è il suo determinante. Il segno del determinante non è importante qui, perché per il calcolo dell'integrale non importa come viene cambiata l'orientazione da Ψ . Si consiglia un video di Grant Sanderson, un divulgatore su YouTube, che fornisce una spiegazione visuale del determinante molto efficace: https://www.youtube.com/watch?v=Ip3X9L0h2dk&ab_channel=3Blue1Brown.

Per concludere, usiamo il cambio di variabile $y = \frac{1}{\sqrt{2x}}$ per calcolare

$$\int_{\mathbb{R}} e^{-\frac{1}{2}x^2} dx = \int_{\mathbb{R}} e^{-y^2} \sqrt{2} dy = \sqrt{2}\sqrt{\pi} = \sqrt{2\pi}.$$

□

► In merito alla presenza di π nel calcolo di questo integrale e, in generale, per altre idee sulla legge normale, si consiglia il video del canale di divulgazione 3Blue1Brown di Grant Sanderson al seguente link: <https://youtu.be/cy8r7WSuT1I?si=KIbXmZ40YRuEsyP9>.





FIGURA 5.3. *xkcd* 2117. DIFFERENTIATION AND INTEGRATION. Credits: <https://xkcd.com/2117/>

DEFINIZIONE 5.9. Una variabile aleatoria $Z: \Omega \rightarrow \mathbb{R}$ è distribuita con *legge normale standard* se ha funzione di densità di probabilità data dalla gaussiana

$$f_Z(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}.$$


Scriveremo $Z \sim \mathcal{N}(0, 1)$. Si veda la Figura 5.4.

FIGURA 5.4. Densità di una variabile aleatoria $X \sim \mathcal{N}(0, 1)$.

</> Link a grafico interattivo in cui si può studiare l'aspetto della funzione di densità di probabilità della legge normale al variare di μ e σ^2 : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/normal.html

La funzione di distribuzione cumulativa di una legge normale standard si denota tipicamente con Φ , ovvero

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt.$$

FIGURA 5.5. Funzione di distribuzione cumulativa Φ di una variabile aleatoria $X \sim \mathcal{N}(0, 1)$.

□

OSSERVAZIONE 5.10. I valori della funzione di distribuzione cumulativa normale Φ sono tipicamente raccolti in tavole.

x Per costruire la tavola della funzione di distribuzione cumulativa normale in un foglio di calcolo è utile utilizzare il comando `DISTRIB.NORM(x;0,1;VERO)`. □

PROPOSIZIONE 5.11. Sia $Z \sim \mathcal{N}(0, 1)$. Allora $\mathbb{E}(Z) = 0$ e $\text{Var}(Z) = 1$.

DIMOSTRAZIONE. Calcoliamo

$$\begin{aligned} \mathbb{E}(Z) &= \int_{-\infty}^{+\infty} x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx \quad \blacksquare \text{ sostituzione } y = \frac{1}{2}x^2, dy = x dx \\ &= \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-y} dy = \frac{1}{\sqrt{2\pi}} \left[-e^{-y} \right]_{y \rightarrow -\infty}^{y \rightarrow +\infty} = 0. \end{aligned}$$

Calcoliamo

$$\begin{aligned} \text{Var}(Z) &= \int_{-\infty}^{+\infty} x^2 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx \quad \blacksquare \text{ integrando per parti} \\ &= \left[-x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \right]_{x \rightarrow -\infty}^{x \rightarrow +\infty} + \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx = 1. \end{aligned}$$

Questo conclude la dimostrazione. \square

OSSERVAZIONE 5.12. Ricordando il comportamento del valore atteso e della varianza rispetto a trasformazioni affini delle variabili aleatorie ricavati nelle Osservazioni 3.40 e 3.60, otteniamo il seguente fatto. Sia $Z \sim \mathcal{N}(0, 1)$ e siano $\mu \in \mathbb{R}$ e $\sigma > 0$. Allora la variabile aleatoria $X = \sigma Z + \mu$ ha valore atteso μ e varianza σ^2 , poiché

$$\mathbb{E}(X) = \mathbb{E}(\sigma Z + \mu) = \sigma \mathbb{E}(Z) + \mu = \mu,$$

$$\text{Var}(X) = \text{Var}(\sigma Z + \mu) = \text{Var}(\sigma Z) = \sigma^2 \text{Var}(Z) = \sigma^2.$$

Calcoliamo la funzione di densità di probabilità di X . Per farlo, calcoliamo la funzione di distribuzione cumulativa

$$\begin{aligned} F_X(x) &= \mathbb{P}(\{X \leq x\}) = \mathbb{P}(\{\sigma Z + \mu \leq x\}) = \mathbb{P}\left(\left\{Z \leq \frac{x - \mu}{\sigma}\right\}\right) \\ &= \int_{-\infty}^{\frac{x - \mu}{\sigma}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz \\ &\quad \blacksquare \text{ cambio di variabile } y = \sigma z + \mu, \quad dy = \sigma dz \\ &= \int_{-\infty}^x \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{y - \mu}{\sigma}\right)^2} dy. \end{aligned}$$

Derivando rispetto a x otteniamo

$$f_X(x) = F'_X(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x - \mu}{\sigma}\right)^2}.$$

\square

La precedente osservazione giustifica la seguente definizione.

DEFINIZIONE 5.13. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ è distribuita con *legge normale standard* con parametri μ e σ^2 se ha funzione di densità di probabilità

$$f_X(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x - \mu}{\sigma}\right)^2}.$$

Scriveremo $X \sim \mathcal{N}(\mu, \sigma^2)$. Per l'Osservazione 5.12 si ha che $\mathbb{E}(X) = \mu$ e $\text{Var}(X) = \sigma^2$. \square

PROPOSIZIONE 5.14. *Siano $X \sim \mathcal{N}(\mu, \sigma^2)$ e $Y \sim \mathcal{N}(\nu, \tau^2)$ indipendenti, dove $\mu, \nu \in \mathbb{R}$ e $\sigma, \tau > 0$. Allora $X + Y \sim \mathcal{N}(\mu + \nu, \sigma^2 + \tau^2)$.*

DIMOSTRAZIONE. È sufficiente dimostrare il risultato nel caso in cui $X \sim \mathcal{N}(0, \sigma^2)$ e $Y \sim \mathcal{N}(0, \tau^2)$.² Ricordiamo che la densità della somma di due variabili aleatorie indipendenti è data dalla convoluzione delle densità delle due variabili aleatorie, si veda la

²In caso contrario, lavoriamo con $(X - \mu) \sim \mathcal{N}(0, \sigma^2)$ e $(Y - \nu) \sim \mathcal{N}(0, \tau^2)$. Se dimostriamo che $(X - \mu) + (Y - \nu) \sim \mathcal{N}(0, \sigma^2 + \tau^2)$, allora $X + Y = (X - \mu) + (Y - \nu) + \mu + \nu \sim \mathcal{N}(\mu + \nu, \sigma^2 + \tau^2)$ in quanto è la traslazione di una legge normale.

Proposizione 3.50. Quindi

$$\begin{aligned}
f_{X+Y}(z) &= f_X * f_Y(z) = \int_{-\infty}^{+\infty} f_X(x) f_Y(z-x) dx \\
&= \int_{-\infty}^{+\infty} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x}{\sigma}\right)^2} \frac{1}{\tau\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z-x}{\tau}\right)^2} dx \\
&= \frac{1}{\sigma\tau 2\pi} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}\left(\frac{x^2}{\sigma^2} + \frac{z^2 - 2zx + x^2}{\tau^2}\right)} dx \\
&= \frac{1}{\sigma\tau 2\pi} \int_{-\infty}^{+\infty} e^{-\frac{1}{2\sigma^2\tau^2}[(\sigma^2 + \tau^2)x^2 - 2\sigma^2zx + \sigma^2z^2]} dx \\
&= \frac{1}{\sigma\tau 2\pi} \int_{-\infty}^{+\infty} e^{-\frac{1}{2\sigma^2\tau^2}\left[(\sigma^2 + \tau^2)x^2 - 2\frac{\sigma^2}{\sqrt{\sigma^2 + \tau^2}}\sqrt{\sigma^2 + \tau^2}zx + \frac{\sigma^4}{\sigma^2 + \tau^2}z^2 - \frac{\sigma^4}{\sigma^2 + \tau^2}z^2 + \sigma^2z^2\right]} dx \\
&= \frac{1}{\sigma\tau 2\pi} \int_{-\infty}^{+\infty} e^{-\frac{1}{2\sigma^2\tau^2}\left[\left(\sqrt{\sigma^2 + \tau^2}x - \frac{\sigma^2}{\sqrt{\sigma^2 + \tau^2}}z\right)^2 + \frac{\sigma^2\tau^2z^2}{\sigma^2 + \tau^2}\right]} dx \\
&= \frac{1}{\sigma\tau 2\pi} \int_{-\infty}^{+\infty} e^{-\frac{1}{2\sigma^2\tau^2}\left[\left(\sqrt{\sigma^2 + \tau^2}x - \frac{\sigma^2}{\sqrt{\sigma^2 + \tau^2}}z\right)^2 + \frac{\sigma^2\tau^2z^2}{\sigma^2 + \tau^2}\right]} dx \\
&= \frac{1}{\sigma\tau 2\pi} e^{-\frac{1}{2}\frac{z^2}{\sigma^2 + \tau^2}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}\left(\frac{\sqrt{\sigma^2 + \tau^2}}{\sigma\tau}x - \frac{\sigma^2}{\sigma\tau\sqrt{\sigma^2 + \tau^2}}z\right)^2} dx \\
&= \frac{1}{\sqrt{\sigma^2 + \tau^2}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z}{\sqrt{\sigma^2 + \tau^2}}\right)^2} \frac{\sqrt{\sigma^2 + \tau^2}}{\sigma\tau\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}\left(\frac{x - \frac{\sigma^2}{\sigma^2 + \tau^2}z}{\sigma\tau/\sqrt{\sigma^2 + \tau^2}}\right)^2} dx \\
&= \frac{1}{\sqrt{\sigma^2 + \tau^2}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z}{\sqrt{\sigma^2 + \tau^2}}\right)^2},
\end{aligned}$$

dove abbiamo utilizzato il fatto che

$$\frac{\sqrt{\sigma^2 + \tau^2}}{\sigma\tau\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}\left(\frac{x - \frac{\sigma^2}{\sigma^2 + \tau^2}z}{\sigma\tau/\sqrt{\sigma^2 + \tau^2}}\right)^2} dx = 1,$$

poiché $\frac{\sqrt{\sigma^2 + \tau^2}}{\sigma\tau\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x - \frac{\sigma^2}{\sigma^2 + \tau^2}z}{\sigma\tau/\sqrt{\sigma^2 + \tau^2}}\right)^2}$ è la densità di una legge normale con media $\frac{\sigma^2}{\sigma^2 + \tau^2}z$ e deviazione standard $\frac{\sigma\tau}{\sqrt{\sigma^2 + \tau^2}}$. La funzione $\frac{1}{\sqrt{\sigma^2 + \tau^2}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z}{\sqrt{\sigma^2 + \tau^2}}\right)^2}$ è la densità di una legge normale $\mathcal{N}(0, \sigma^2 + \tau^2)$ e questo conclude la dimostrazione. \square

► Per un'idea del perché la convoluzione di due gaussiane è una gaussiana, si consiglia il video del canale di divulgazione 3Blue1Brown di Grant Sanderson al seguente link: <https://youtu.be/cy8r7WSuT1I?si=KIbXmZ40YRuEsyP9>.

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 5.15. Sia X una variabile aleatoria con legge normale con parametri $\mu = 10$ e $\sigma^2 = 36$. Calcolare: $\mathbb{P}(\{X > 5\})$, $\mathbb{P}(\{4 < X < 16\})$, $\mathbb{P}(\{X < 8\})$, $\mathbb{P}(\{X < 20\})$, $\mathbb{P}(\{X > 16\})$. \square

ESERCIZIO 5.16. Un'azienda produce bulloni con diametro dichiarato tra 1.19 e 1.21 pollici. Se i bulloni che escono dalla linea di produzione hanno un diametro distribuito con una legge normale con $\mu = 1.20$ e $\sigma = 0.005$, che percentuale non soddisfa le specifiche? \square

ESERCIZIO 5.17. Un certo tipo di lampadine ha una luminosità con distribuzione normale con $\mu = 2000$ e $\sigma^2 = 85$. Determina un limite inferiore della luminosità da dichiarare affinché non più del 5% di lampadine prodotte non lo rispettino. \square

ESERCIZIO 5.18. La distanza tra due punti deve essere misurata (in metri). La vera distanza tra i punti è di 10 metri, ma a causa di un errore di misurazione non possiamo misurare esattamente la distanza. Osserveremo invece un valore di $10 + \epsilon$, dove l'errore ϵ è distribuito $\mathcal{N}(0, 0.04)$. Trovare la probabilità che la distanza osservata sia entro 0.4 metri dalla distanza reale (10 metri). \square

ESERCIZIO 5.19. Alice sta cercando di trasmettere a Bob la risposta a una domanda con risposta sì-no, usando un canale rumoroso. Codifica "sì" come 1 e "no" come 0 e invia il valore a Bob. Tuttavia, il canale aggiunge rumore; in particolare, Bob riceve ciò che Alice invia più un termine di rumore con distribuzione $\mathcal{N}(0, \sigma^2)$ (il rumore è indipendente da ciò che Alice invia). Se Bob riceve un valore maggiore di $1/2$ lo interpreta come "sì"; altrimenti lo interpreta come "no".

- (1) Trovare la probabilità che Bob interpreti correttamente il messaggio di Alice.
- (2) Cosa succede al risultato del punto precedente se σ è molto piccolo? E se σ è molto grande? Spiegare intuitivamente perché i risultati in questi casi estremi hanno senso. \square

ESERCIZIO 5.20. Siano $X \sim \mathcal{N}(\mu, \sigma^2)$ e $Y \sim \mathcal{N}(\nu, \tau^2)$ indipendenti. Trovare la probabilità che $X < Y$ (Suggerimento: $X - Y < 0$). \square

ESERCIZIO 5.21. Sia Y un punto scelto sulla retta reale secondo una legge normale standard. Calcolare il valore atteso dell'area del cerchio di raggio $|Y|$. \square

5.3. Legge esponenziale

La legge esponenziale descrive tempi di attesa con assenza di memoria.

DEFINIZIONE 5.22. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ è distribuita con *legge esponenziale* con parametro $\lambda > 0$ se ha funzione di densità di probabilità

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

Scriveremo $X \sim \text{Exp}(\lambda)$. Si veda la Figura 5.6. \square




FIGURA 5.6. Densità di una variabile aleatoria $X \sim \text{Exp}(\lambda)$.

✎ Link a grafico interattivo in cui si può studiare l'aspetto della funzione di densità di probabilità della legge esponenziale al variare di λ : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/exponential.html

OSSERVAZIONE 5.23. Osserviamo che c'è una formula molto pratica per il calcolo della probabilità che una variabile aleatoria con legge esponenziale sia più grande di un certo valore. Per ogni $t > 0$ si ha che

$$\mathbb{P}(\{X > t\}) = \int_t^{+\infty} \lambda e^{-\lambda x} dx = \left[-e^{-\lambda x} \right]_{x=t}^{x \rightarrow +\infty} = e^{-\lambda t}.$$

Quindi la probabilità che una variabile aleatoria con legge esponenziale sia più grande di t decade esponenzialmente con t . Il tasso di decadimento esponenziale è λ .

Segue che la funzione di distribuzione cumulativa di una variabile aleatoria $X \sim \text{Exp}(\lambda)$ è $1 - e^{-\lambda t}$. Si veda la Figura 5.7




FIGURA 5.7. Funzione di distribuzione cumulativa di una variabile aleatoria $X \sim \text{Exp}(\lambda)$.

□

La legge esponenziale gode della proprietà di assenza di memoria.

PROPOSIZIONE 5.24. Sia $X \sim \text{Exp}(\lambda)$. Allora

$$\mathbb{P}(\{X > s+t\} | \{X > s\}) = \mathbb{P}(\{X > t\})$$

per ogni $s, t > 0$.

DIMOSTRAZIONE. Per l'Osservazione 5.23 abbiamo che

$$\begin{aligned} \mathbb{P}(\{X > s+t\} | \{X > s\}) &= \frac{\mathbb{P}(\{X > s+t\} \cap \{X > s\})}{\mathbb{P}(\{X > s\})} = \frac{\mathbb{P}(\{X > s+t\})}{\mathbb{P}(\{X > s\})} \\ &= \frac{e^{-\lambda(s+t)}}{e^{-\lambda s}} = e^{-\lambda t} = \mathbb{P}(\{X > t\}). \end{aligned}$$

Questo conclude la dimostrazione. \square

OSSERVAZIONE 5.25. \blacktriangle Si può dimostrare che la legge esponenziale è l'unica legge con una funzione di densità di probabilità con range in $[0, +\infty)$ a godere della proprietà di assenza di memoria. Infatti, sia X una variabile aleatoria con densità f_X (di cui non conosciamo la forma esplicita) tale che $f_X(x) = 0$ per $x < 0$. Se vale la proprietà di assenza di memoria, si ha che

$$\begin{aligned}\mathbb{P}(\{X > s+t\}|\{X > s\}) &= \mathbb{P}(\{X > t\}) \\ \implies \mathbb{P}(\{X > s+t\}) &= \mathbb{P}(\{X > t\})\mathbb{P}(\{X > s\}) \\ \implies \int_{s+t}^{+\infty} f_X(x) dx &= \left(\int_s^{+\infty} f_X(x) dx\right)\left(\int_t^{+\infty} f_X(x) dx\right)\end{aligned}$$

per $s, t \geq 0$. Derivando rispetto a t otteniamo che

$$f_X(s+t) = \left(\int_s^{+\infty} f_X(x) dx\right)f_X(t)$$

e ponendo $t = 0$

$$f_X(s) = \left(\int_s^{+\infty} f_X(x) dx\right)f_X(0) = \lambda\left(\int_s^{+\infty} f_X(x) dx\right),$$

dove abbiamo posto $\lambda = f_X(0)$. Segue che f_X è (l'opposta) di una funzione integrale, quindi è derivabile. Deriviamo rispetto a s e otteniamo che

$$f'_X(s) = -\lambda f_X(s).$$

Questa è una equazione differenziale ordinaria lineare omogenea. Le soluzioni di questa equazione differenziale sono della forma

$$f_X(s) = Ce^{-\lambda s}, \quad C \in \mathbb{R}.$$

Tra le costanti C , una sola è tale che $\int_0^{+\infty} f_X(x) dx = 1$. Ovvero $C = \lambda$. \square

PROPOSIZIONE 5.26. *Sia $X \sim \text{Exp}(\lambda)$. Allora $\mathbb{E}(X) = \frac{1}{\lambda}$ e $\text{Var}(X) = \frac{1}{\lambda^2}$.*

DIMOSTRAZIONE. Integrando per parti, otteniamo che

$$\begin{aligned}\mathbb{E}(X) &= \int_0^{+\infty} x\lambda e^{-\lambda x} dx = \left[-xe^{-\lambda x}\right]_{x=0}^{x \rightarrow +\infty} + \int_0^{+\infty} e^{-\lambda x} dx \\ &= 0 + \left[-\frac{1}{\lambda}e^{-\lambda x}\right]_{x=0}^{x \rightarrow +\infty} = \frac{1}{\lambda}.\end{aligned}$$

Ancora integrando per parti, otteniamo che

$$\begin{aligned}\text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \int_0^{+\infty} x^2\lambda e^{-\lambda x} dx - \frac{1}{\lambda^2} \\ &= \left[-x^2e^{-\lambda x}\right]_{x=0}^{x \rightarrow +\infty} + \int_0^{+\infty} 2xe^{-\lambda x} dx - \frac{1}{\lambda^2} \\ &= 0 + \frac{2}{\lambda} \int_0^{+\infty} x\lambda e^{-\lambda x} dx - \frac{1}{\lambda^2} \\ &= \frac{2}{\lambda}\mathbb{E}(X) - \frac{1}{\lambda^2} = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}.\end{aligned}$$

□

OSSERVAZIONE 5.27.  La legge esponenziale è la versione continua della legge geometrica. Più precisamente, è il limite ottenuto quando le prove di Bernoulli vengono effettuate sempre più rapidamente, con probabilità di successo sempre più piccola. Spieghiamo in che senso.

Consideriamo un intervallo di tempo Δt , un parametro $\lambda > 0$ e $p = \lambda \Delta t$. Si effettuano prove di Bernoulli indipendenti con probabilità p negli istanti di tempo $\Delta t, 2\Delta t, 3\Delta t, \dots$ ottenuti discretizzando il tempo. Sia $X \sim \text{Geo}(p)$. Interpretiamo l'evento $\{X = k\}$ come “il primo successo avviene all'istante di tempo $k\Delta t$ ”. Per descrivere meglio questo fenomeno, definiamo la variabile aleatoria $T = X\Delta t$. Calcoliamo la funzione di distribuzione cumulativa di T per $t > 0$:

$$F_T^{\Delta t}(t) = \mathbb{P}(\{T \leq t\}) = \mathbb{P}(\{X\Delta t \leq t\}) = \mathbb{P}\left(\left\{X \leq \frac{t}{\Delta t}\right\}\right).$$

Poiché X è una variabile discreta, richiedere che $X \leq \frac{t}{\Delta t}$ è equivalente a richiedere che $X \leq k$ dove k è il più grande numero naturale minore o uguale a $\frac{t}{\Delta t}$, ovvero $k \in \mathbb{N}$ e

$$k \leq \frac{t}{\Delta t} < k + 1.$$

Usiamo la notazione $k = \lfloor \frac{t}{\Delta t} \rfloor$. Allora

$$t - \frac{1}{\Delta t} < \Delta t \left\lfloor \frac{t}{\Delta t} \right\rfloor \leq t,$$

da cui segue, per il teorema del confronto,

$$\lim_{\Delta t \rightarrow 0} \Delta t \left\lfloor \frac{t}{\Delta t} \right\rfloor = t.$$

Concludiamo che

$$\begin{aligned} F_T^{\Delta t}(t) &= \mathbb{P}\left(\left\{X \leq \left\lfloor \frac{t}{\Delta t} \right\rfloor\right\}\right) = 1 - \mathbb{P}\left(\left\{X > \left\lfloor \frac{t}{\Delta t} \right\rfloor\right\}\right) = 1 - (1 - p)^{\lfloor \frac{t}{\Delta t} \rfloor} \\ &= 1 - (1 - \lambda \Delta t)^{-\frac{1}{\lambda \Delta t}(-\lambda \Delta t \lfloor \frac{t}{\Delta t} \rfloor)} \xrightarrow{\Delta t \rightarrow 0} 1 - e^{-\lambda t}. \end{aligned}$$

Osserviamo che $1 - e^{-\lambda t}$ è la funzione di distribuzione cumulativa di una variabile aleatoria $X \sim \text{Exp}(\lambda)$.

□

Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 5.28. Il tempo (in ore) necessario per riparare una macchina è una variabile aleatoria distribuita con legge esponenziale con parametro $\lambda = 1$.

- (1) Qual è la probabilità che un tempo di riparazione superi le 2 ore?
- (2) Qual è la probabilità che una riparazione richieda almeno 3 ore, sapendo che la sua durata supera le 2 ore?

□

ESERCIZIO 5.29. Il numero di anni di funzionamento di una radio è distribuito in modo esponenziale con parametro $\lambda = 1/8$. Se Bob acquista una radio usata funzionante, qual è la probabilità che funzioni dopo altri 10 anni? \square

ESERCIZIO 5.30. Il numero di giorni in anticipo che i viaggiatori acquistano i biglietti aerei può essere modellato da una distribuzione esponenziale con un tempo medio pari a 15 giorni. Trova la probabilità che un viaggiatore acquisti un biglietto con meno di dieci giorni di anticipo. \square

ESERCIZIO 5.31. Supponiamo che su un certo tratto di autostrada il tempo trascorso tra due auto successive abbia una distribuzione esponenziale con una media di 12 secondi.

- (1) Dopo il passaggio di un'auto, quanto tempo impiegheranno in media altre sette auto a passare?
- (2) Trova la probabilità che dopo il passaggio di un'auto, l'auto successiva passi entro i prossimi 20 secondi.
- (3) Trova la probabilità che dopo il passaggio di un'auto, l'auto successiva non passi per almeno altri 15 secondi.

\square

ESERCIZIO 5.32. Alice vuole vendere la sua macchina, dopo essere tornata a Bari (dove è soddisfatta del sistema di autobus). Decide di venderla alla prima persona che gli offre almeno €18.000. Supponiamo che le offerte siano variabili casuali esponenziali indipendenti con una media di €12.000 e che Alice sia in grado di continuare a ricevere offerte fino a quando non ne ottiene una che soddisfi il suo criterio. Trova il numero atteso di offerte che Alice riceverà per l'auto prima di accettare. \square

5.4. Legge Gamma

OSSERVAZIONE 5.33. La somma di due variabili aleatorie indipendenti distribuite con legge esponenziale con stesso parametro non ha distribuzione esponenziale. Per mostrare questo fatto, consideriamo due variabili aleatorie $X_1, X_2 \sim \text{Exp}(\lambda)$ indipendenti e calcoliamo la funzione di densità di probabilità della somma $X_1 + X_2$. Per la Proposizione 3.50 questa densità è data dalla convoluzione delle densità di X_1 e X_2 , quindi, per $x > 0$,

$$\begin{aligned} f_{X_1+X_2}(x) &= f_{X_1} * f_{X_2}(x) = \int_{-\infty}^{+\infty} f_{X_1}(y) f_{X_2}(x-y) dy \\ &= \int_0^x \lambda e^{-\lambda y} \lambda e^{-\lambda(x-y)} dy = \lambda^2 e^{-\lambda x} \int_0^x 1 dy = \lambda^2 x e^{-\lambda x}. \end{aligned}$$

Per $x \leq 0$, entrambe le densità nella formula di sopra sono nulle. In conclusione,

$$f_{X_1+X_2}(x) = \begin{cases} \lambda^2 x e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

Questa non è la densità di una legge esponenziale.

Consideriamo una terza variabile aleatoria $X_3 \sim \text{Exp}(\lambda)$ indipendente da X_1 e X_2 . Allora $X_1 + X_2$ e X_3 sono indipendenti. Calcoliamo la densità di $X_1 + X_2 + X_3$ utilizzando

ancora la convoluzione. Per $x > 0$ si ha che

$$\begin{aligned} f_{X_1+X_2+X_3}(x) &= f_{X_1+X_2} * f_{X_3}(x) = \int_{-\infty}^{+\infty} f_{X_1+X_2}(y) f_{X_3}(x-y) dy \\ &= \int_0^x \lambda^2 y e^{-\lambda y} \lambda e^{-\lambda(x-y)} dy = \lambda^3 e^{-\lambda x} \int_0^x y dy = \frac{\lambda^2}{2} x^2 e^{-\lambda x}. \end{aligned}$$

Per $x \leq 0$ si ha $f_{X_1+X_2+X_3}(x) = 0$. Concludiamo che

$$f_{X_1+X_2+X_3}(x) = \begin{cases} \frac{\lambda^3}{2} x^2 e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

□

ESERCIZIO 5.34. Mostrare con un argomento induttivo che, date $n \geq 1$ variabili aleatorie $X_1, \dots, X_n \sim \text{Exp}(\lambda)$ indipendenti, la somma $X = X_1 + \dots + X_n$ ha densità

$$f_X(x) = \begin{cases} \frac{\lambda^n}{(n-1)!} x^{n-1} e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

□

Per trattare questo tipo di variabili aleatorie, introduciamo una nuova legge generale, in cui il numero naturale n viene sostituito da un parametro reale $\alpha > 0$. Occorre capire come adattare il valore $\frac{\lambda^n}{(n-1)!}$, poiché il fattoriale è ben definito solo per i numeri naturali.

OSSERVAZIONE 5.35. Consideriamo una variabile aleatoria X con funzione di densità di probabilità

$$f_X(x) = \begin{cases} c_{\alpha,\lambda} x^{\alpha-1} e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti,} \end{cases}$$

dove la costante $c_{\alpha,\lambda}$ è da determinare. Imponiamo che

$$1 = \int_{-\infty}^{+\infty} f_X(x) dx = \int_0^{+\infty} c_{\alpha,\lambda} x^{\alpha-1} e^{-\lambda x} dx.$$

Con il cambio di variabili $y = \lambda x$ otteniamo che

$$1 = c_{\alpha,\lambda} \int_0^{+\infty} \left(\frac{y}{\lambda}\right)^{\alpha-1} e^{-y} \frac{1}{\lambda} dy = c_{\alpha,\lambda} \frac{1}{\lambda^\alpha} \int_0^{+\infty} y^{\alpha-1} e^{-y} dy$$

da cui segue

$$c_{\alpha,\lambda} = \lambda^\alpha \frac{1}{\int_0^{+\infty} y^{\alpha-1} e^{-y} dy}.$$

□

DEFINIZIONE 5.36. La *funzione Gamma di Eulero* è la funzione definita per ogni $\alpha > 0$ da

$$\Gamma(\alpha) = \int_0^{+\infty} y^{\alpha-1} e^{-y} dy.$$

□



FIGURA 5.8. Leonhard Euler (1707-1783).^a Uno dei più importanti matematici della storia. Il suo nome è associato a tantissimi strumenti della matematica e della fisica.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Leonhard_Euler_2.jpg

OSSERVAZIONE 5.37. La funzione Gamma di Eulero è una generalizzazione del fattoriale ai numeri reali positivi. Più precisamente:

$$\Gamma(n) = (n - 1)!, \quad \text{per ogni } n \in \mathbb{N}, n \geq 1.$$

Questo è compatibile con quanto mostrato nell'Esercizio 5.34. Dimostriamo la seguente formula

$$\Gamma(\alpha) = (\alpha - 1)\Gamma(\alpha - 1) \quad \text{per } \alpha > 1.$$

Integrando per parti abbiamo che

$$\begin{aligned} \Gamma(\alpha) &= \int_0^{+\infty} \underbrace{y^{\alpha-1}}_f \underbrace{e^{-y}}_{g'} dy \\ &= \left[\underbrace{y^{\alpha-1}}_f \underbrace{(-e^{-y})}_g \right]_{y=0}^{y \rightarrow +\infty} - \int_0^{+\infty} \underbrace{(\alpha-1)y^{\alpha-2}}_{f'} \underbrace{(-e^{-y})}_g dy \\ &= (\alpha-1) \int_0^{+\infty} y^{\alpha-2} e^{-y} dy \\ &= (\alpha-1)\Gamma(\alpha-1). \end{aligned}$$

In particolare, se $\alpha = n \in \mathbb{N}$ abbiamo che

$$\Gamma(n) = (n-1)\Gamma(n-1).$$

Applichiamo a catena l'uguaglianza precedente, arrivando a calcolare

$$\Gamma(1) = \int_0^{+\infty} e^{-y} dy = 1,$$

perché e^{-y} per $y > 0$ è la densità di una legge $\text{Exp}(1)$. Segue la tesi. \square

DEFINIZIONE 5.38. Una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$ è distribuita con *legge Gamma* con parametri $\alpha > 0$, $\lambda > 0$ se ha funzione di densità di probabilità

$$f_X(x) = \begin{cases} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

Scriveremo $X \sim \text{Gamma}(\alpha, \lambda)$. □




FIGURA 5.9. Esempi di densità di una variabile aleatoria $X \sim \text{Gamma}(\alpha, \lambda)$.

◀/> Link a grafico interattivo in cui si può studiare l'aspetto della funzione di densità di probabilità della legge Gamma al variare di α e λ : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/gamma.html

PROPOSIZIONE 5.39. Sia $X \sim \text{Gamma}(\alpha, \lambda)$. Allora

$$\mathbb{E}(X) = \frac{\alpha}{\lambda}, \quad \text{Var}(X) = \frac{\alpha}{\lambda^2}.$$

DIMOSTRAZIONE. Calcoliamo il valore atteso:

$$\begin{aligned} \mathbb{E}(X) &= \int_{-\infty}^{+\infty} x f_X(x) dx = \int_0^{+\infty} x \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} dx \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \int_0^{+\infty} x^\alpha e^{-\lambda x} dx \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{\Gamma(\alpha+1)}{\lambda^{\alpha+1}} \int_0^{+\infty} \frac{\lambda^{\alpha+1}}{\Gamma(\alpha+1)} x^{(\alpha+1)-1} e^{-\lambda x} dx \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{\alpha \Gamma(\alpha)}{\lambda^{\alpha+1}} = \frac{\alpha}{\lambda}, \end{aligned}$$

dove abbiamo usato che l'integranda è la densità di una variabile aleatoria con legge $\text{Gamma}(\alpha+1, \lambda)$ e la proprietà $\Gamma(\alpha+1) = \alpha \Gamma(\alpha)$ della funzione Gamma di Eulero.

Per calcolare la varianza, usiamo la formula

$$\begin{aligned}
 \text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \int_{-\infty}^{+\infty} x^2 f_X(x) dx - \frac{\alpha^2}{\lambda^2} \\
 &= \int_0^{+\infty} x^2 \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} dx - \frac{\alpha^2}{\lambda^2} \\
 &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{\Gamma(\alpha+2)}{\lambda^{\alpha+2}} \int_0^{+\infty} \frac{\lambda^{\alpha+2}}{\Gamma(\alpha+2)} x^{\alpha+1} e^{-\lambda x} dx - \frac{\alpha^2}{\lambda^2} \\
 &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{(\alpha+1)\alpha\Gamma(\alpha)}{\lambda^{\alpha+2}} \int_0^{+\infty} \frac{\lambda^{\alpha+2}}{\Gamma(\alpha+2)} x^{(\alpha+2)-1} e^{-\lambda x} dx - \frac{\alpha^2}{\lambda^2} \\
 &= \frac{\alpha^2 + \alpha}{\lambda^2} - \frac{\alpha^2}{\lambda^2} = \frac{\alpha}{\lambda^2},
 \end{aligned}$$

usato che l'integranda è la densità di una variabile aleatoria con legge Gamma($\alpha + 2, \lambda$) e la proprietà $\Gamma(\alpha + 2) = (\alpha + 1)\Gamma(\alpha + 1) = (\alpha + 1)\alpha\Gamma(\alpha)$ della funzione Gamma di Eulero. \square

Ora dimostriamo una proprietà che generalizza ciò che abbiamo visto nell'Osservazione 5.33.

PROPOSIZIONE 5.40. *Siano $X \sim \text{Gamma}(\alpha, \lambda)$ e $Y \sim \text{Gamma}(\beta, \lambda)$ indipendenti. Allora $X + Y \sim \text{Gamma}(\alpha + \beta, \lambda)$.*

DIMOSTRAZIONE. Per la Proposizione 3.50, la densità della somma $X + Y$ è data dalla convoluzione delle densità di X e Y . Questa densità è nulla per $z \leq 0$. Per $z > 0$,

$$\begin{aligned}
 f_{X+Y}(z) &= \int_{-\infty}^{+\infty} f_X(x) f_Y(z-x) dx \\
 &= \int_0^z \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} \frac{\lambda^\beta}{\Gamma(\beta)} (z-x)^{\beta-1} e^{-\lambda(z-x)} dx \\
 &= \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} e^{-\lambda z} \int_0^z x^{\alpha-1} (z-x)^{\beta-1} dx \quad \blacktriangleleft \text{sostituzione } y = \frac{x}{z} \\
 &\quad \blacktriangleleft dx = z dy \\
 &= \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} z^{\alpha+\beta-1} e^{-\lambda z} \int_0^1 y^{\alpha-1} (1-y)^{\beta-1} dy.
 \end{aligned}$$

La quantità $\int_0^1 y^{\alpha-1} (1-y)^{\beta-1} dy$ è una costante. A meno del fattore di proporzionalità $\frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} \int_0^1 y^{\alpha-1} (1-y)^{\beta-1} dy$, abbiamo ottenuto la densità di una variabile aleatoria distribuita con legge Gamma($\alpha + \beta, \lambda$). A posteriori, concludiamo che la costante deve essere necessariamente uguale a $\frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha+\beta)}$ in modo che l'integrale della densità sia 1. Questo conclude la dimostrazione. \square

OSSERVAZIONE 5.41. Come sottoprodotto della dimostrazione precedente, otteniamo una proprietà della funzione Γ di Eulero, ovvero,

$$\frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} = \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha+\beta)} \int_0^1 y^{\alpha-1} (1-y)^{\beta-1} dy,$$

da cui

$$\Gamma(\alpha + \beta) = \Gamma(\alpha)\Gamma(\beta) \int_0^1 y^{\alpha-1}(1-y)^{\beta-1} dy.$$

□

5.5. Legge chi-quadro

In questa sezione studiamo una variabile aleatoria che sarà utilizzata molto nell'ultima parte del corso sulla statistica inferenziale.

Prima di fornire la definizione della legge chi-quadro, facciamo due osservazioni preliminari.

OSSERVAZIONE 5.42. Consideriamo $Z \sim \mathcal{N}(0, 1)$. Calcoliamo la densità della variabile aleatoria Z^2 . Per farlo, calcoliamo la funzione di distribuzione cumulativa di Z^2 . Per ogni $z \geq 0$ abbiamo che

$$\begin{aligned} \mathbb{P}(\{Z^2 \leq z\}) &= \mathbb{P}(\{-\sqrt{z} \leq Z \leq \sqrt{z}\}) = \int_{-\sqrt{z}}^{\sqrt{z}} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \\ &= 2 \int_0^{\sqrt{z}} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \quad \blacksquare \text{ sostituzione } y = x^2 \\ \blacksquare dy &= 2x dx \implies 2dx = y^{-\frac{1}{2}} dy \\ &= \int_0^z \frac{1}{\sqrt{2\pi}} y^{-\frac{1}{2}} e^{-\frac{y}{2}} dy. \end{aligned}$$

Quindi la densità di Z^2 è data da

$$f_{Z^2}(x) = \begin{cases} \frac{1}{\sqrt{2\pi}} x^{-\frac{1}{2}} e^{-\frac{x}{2}}, & \text{se } x > 0, \\ 0, & \text{altrimenti.} \end{cases}$$

A meno del fattore costante di proporzionalità $\frac{1}{\sqrt{2\pi}}$, questa è la densità di una variabile aleatoria distribuita con legge Gamma con parametri $\alpha = \frac{1}{2}$ e $\lambda = \frac{1}{2}$. Segue che $Z^2 \sim \text{Gamma}(\frac{1}{2}, \frac{1}{2})$.

A posteriori, deduciamo anche che $\frac{1}{\sqrt{2\pi}} = \frac{\lambda^\alpha}{\Gamma(\alpha)} = \frac{(\frac{1}{2})^{\frac{1}{2}}}{\Gamma(\frac{1}{2})}$ da cui

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}.$$

Questo permette di calcolare, tramite la formula iterativa della funzione Γ di Eulero, tutti i valori della forma $\Gamma(\frac{n}{2})$. □

Utilizziamo il risultato sulla somma di variabili aleatorie indipendenti con legge Gamma, la Proposizione 5.40, per generalizzare l'osservazione precedente.

OSSERVAZIONE 5.43. Consideriamo delle variabili aleatorie $Z_1, \dots, Z_n \sim \mathcal{N}(0, 1)$ indipendenti. Allora $Z_1^2, \dots, Z_n^2 \sim \text{Gamma}(\frac{1}{2}, \frac{1}{2})$. Inoltre Z_1^2, \dots, Z_n^2 sono indipendenti, perché funzioni di variabili aleatorie indipendenti, si veda la Proposizione 3.29. Per la Proposizione 5.40 concludiamo che $Z_1^2 + \dots + Z_n^2 \sim \text{Gamma}(\frac{n}{2}, \frac{1}{2})$. □

Per il ruolo fondamentale che la legge $\text{Gamma}(\frac{n}{2}, \frac{1}{2})$ gioca nella statistica inferenziale, viene dato un nome a questa legge.

DEFINIZIONE 5.44. Sia $n \in \mathbb{N}$, $n \geq 1$. Sia $Q_n \sim \text{Gamma}(\frac{n}{2}, \frac{1}{2})$ una variabile aleatoria distribuita con legge Gamma con parametri $\alpha = \frac{n}{2}$ e $\lambda = \frac{1}{2}$. Diremo che Q_n è distribuita con legge *chi-quadro* con n gradi di libertà. Scriveremo $Q_n \sim \chi^2(n)$. \square

</> Link a grafico interattivo in cui si può studiare l'aspetto della funzione di densità di probabilità della legge chi-quadro al variare di n : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/chi-squared.html

OSSERVAZIONE 5.45. Alcuni valori della funzione di distribuzione cumulativa della legge chi-quadro sono tipicamente raccolti in tavole. Più precisamente, per ogni $n \in \mathbb{N}$, $n \geq 1$, la tavola della legge chi-quadro contiene i valori $\chi_{n,\alpha}^2$ tali che

$$\mathbb{P}(\{Q_n \geq \chi_{n,\alpha}^2\}) = \alpha.$$

x Per costruire la tavola della funzione di distribuzione cumulativa chi-quadro in un foglio di calcolo è utile utilizzare il comando `INV.CHI.QUAD.DS(probabilità; grado_libertà)`. \square

5.6. Legge t-Student

In questa sezione studiamo una variabile aleatoria che sarà utilizzata molto nell'ultima parte del corso sulla statistica inferenziale.

PROPOSIZIONE 5.46. Siano $Z \sim \mathcal{N}(0, 1)$ e $Q_n \sim \chi^2(n)$ indipendenti. Allora la variabile aleatoria

$$T_n = \frac{Z}{\sqrt{Q_n/n}}$$

ha densità

$$f_{T_n}(t) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}$$

per $t \in \mathbb{R}$.

DIMOSTRAZIONE. Da un lato, la funzione di distribuzione cumulativa della variabile aleatoria T_n è data da

$$F_{T_n}(t) = \mathbb{P}(\{T_n \leq t\}) = \int_{-\infty}^t f_{T_n}(x) dx.$$

D'altro canto, possiamo considerare la funzione $H: \mathbb{R} \times (0, +\infty) \rightarrow \mathbb{R} \times (0, +\infty)$ data da $H(z, q) = (\frac{z}{\sqrt{q/n}}, q)$ e osservare che $(T_n, Q_n) = H(Z, Q_n)$. Segue che

$$\begin{aligned}
F_{T_n}(t) &= \mathbb{P}(\{T_n \leq t\}) = \mathbb{P}(\{(T_n, Q_n) \in (-\infty, t] \times (0, +\infty)\}) \\
&= \mathbb{P}(\{H(Z, Q_n) \in (-\infty, t] \times (0, +\infty)\}) = \mathbb{P}(\{(Z, Q_n) \in H^{-1}((-\infty, t] \times (0, +\infty))\}) \\
&\quad \blacksquare \frac{z}{\sqrt{q/n}} \leq t \iff z \leq t\sqrt{\frac{q}{n}} \\
&\quad \blacksquare H^{-1}((-\infty, t] \times (0, +\infty)) = \{(z, q) \text{ t.c. } z \leq t\sqrt{\frac{q}{n}}, q \in (0, +\infty)\} \\
&= \int_0^{+\infty} \left(\int_{-\infty}^{t\sqrt{\frac{q}{n}}} f_{(Z, Q_n)}(z, q) dz \right) dq \\
&\quad \blacksquare \text{ per la Proposizione 3.48} \\
&= \int_0^{+\infty} \left(\int_{-\infty}^{t\sqrt{\frac{q}{n}}} f_Z(z) f_{Q_n}(q) dz \right) dq \\
&\quad \blacksquare \text{ cambio di variabili } \tau = \frac{z}{\sqrt{q/n}} \implies z = \tau\sqrt{\frac{q}{n}} \implies dz = \sqrt{\frac{q}{n}} d\tau \\
&= \int_0^{+\infty} \left(\int_{-\infty}^t f_Z\left(\tau\sqrt{\frac{q}{n}}\right) f_{Q_n}(q) \sqrt{\frac{q}{n}} d\tau \right) dq \\
&= \int_0^{+\infty} \left(\int_{-\infty}^t \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\left(\tau\sqrt{\frac{q}{n}}\right)^2} d\tau \right) \frac{\left(\frac{1}{2}\right)^{\frac{n}{2}}}{\Gamma\left(\frac{n}{2}\right)} q^{\frac{n}{2}-1} e^{-\frac{1}{2}q} \sqrt{\frac{q}{n}} dq \\
&= \frac{1}{\sqrt{\pi n} 2^{\frac{n+1}{2}} \Gamma\left(\frac{n}{2}\right)} \int_{-\infty}^t \int_0^{+\infty} q^{\frac{n-1}{2}} e^{-\frac{1}{2}\left(1+\frac{\tau^2}{n}\right)} dq d\tau.
\end{aligned}$$

Derivando rispetto a t otteniamo la funzione di densità di probabilità di T_n , ovvero

$$f_{T_n}(t) = F'_{T_n}(t) = \frac{1}{\sqrt{n\pi} 2^{\frac{n+1}{2}} \Gamma\left(\frac{n}{2}\right)} \int_0^{+\infty} q^{\frac{n-1}{2}} e^{-\frac{1}{2}\left(1+\frac{t^2}{n}\right)} dq.$$

A meno di un fattore di proporzionalità, la funzione $q^{\frac{n-1}{2}} e^{-\frac{1}{2}\left(1+\frac{t^2}{n}\right)}$ è la densità di una variabile aleatoria distribuita con legge Gamma $\left(\frac{n+1}{2}, \frac{1}{2}\left(1+\frac{t^2}{n}\right)\right)$. Segue che

$$\int_0^{+\infty} q^{\frac{n-1}{2}} e^{-\frac{1}{2}\left(1+\frac{t^2}{n}\right)} dq = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\frac{1}{2^{\frac{n+1}{2}}}\left(1+\frac{t^2}{n}\right)^{\frac{n+1}{2}}}.$$

In conclusione,

$$f_{T_n}(t) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}.$$

Questo conclude la dimostrazione. \square

DEFINIZIONE 5.47. Sia $n \in \mathbb{N}$, $n \geq 1$. Sia T_n una variabile aleatoria con funzione di densità di probabilità

$$f_{T_n}(t) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}$$

per $t \in \mathbb{R}$. Diremo che T_n è distribuita con *legge t-Student* con n gradi di libertà. Scriveremo $T_n \sim t(n)$. \square




FIGURA 5.10. Funzione di densità di probabilità della legge t-Student per $n = 2$ (grigio chiaro), 5 (grigio), 100 (nero).

OSSERVAZIONE 5.48. La funzione di densità di probabilità della legge t-Student ha una forma a campana simile a quella della legge normale, ma con code più pesanti. Quando la utilizzeremo nella statistica inferenziale, capiremo che il motivo della presenza delle code più pesanti è dovuto al fatto che la legge di t-Student è utilizzata quando la varianza della popolazione non è nota e deve essere stimata. \square



FIGURA 5.11. William Sealy Gosset (1876-1937).^a Statistico inglese che ha introdotto la legge t-Student. Usò lo pseudonimo “Student” poiché il birrifico presso il quale lavorava vietava la pubblicazione di articoli per evitare la divulgazione dei segreti di produzione della birra.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:William_Sealy_Gosset.jpg

</> Link a grafico interattivo in cui si può studiare l'aspetto della funzione di densità di probabilità della legge t-Student al variare di n : https://orlandopoliba.github.io/pages/corsi/ProbStat_IngGest/plots/t-student.html

ESERCIZIO 5.49.  Dimostrare che

$$\lim_{n \rightarrow +\infty} f_{T_n}(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}}.$$

□

OSSERVAZIONE 5.50. Alcuni valori della funzione di distribuzione cumulativa della legge t-Student sono tipicamente raccolti in tavole. Più precisamente, per ogni $n \in \mathbb{N}$, $n \geq 1$, la tavola della legge t-Student contiene i valori $t_{n,\alpha}$ tali che

$$\mathbb{P}(\{T_n \geq t_{n,\alpha}\}) = \alpha.$$

 Per costruire la tavola della funzione di distribuzione cumulativa t-Student in un foglio di calcolo è utile utilizzare il comando `INV.T`. □




FIGURA 5.12. xkcd 1347. T-DISTRIBUTION Credits: <https://xkcd.com/1347/>

Statistica inferenziale

Contenuti

6.1. Statistiche e stimatori	151
6.2. Alcune leggi importanti	156
Legge normale	156
Legge chi-quadro	156
Legge t di Student	158
6.3. Teoremi limite	159

Abbiamo finalmente gli strumenti di probabilità per affrontare i problemi della statistica con maturità. Torniamo al problema iniziale presentato nel corso: vogliamo esaminare una variabile di una popolazione. Il nome che avevamo dato alla “variabile” della popolazione non è una coincidenza: poiché, tipicamente, quando misuriamo la variabile in esame su un elemento della popolazione otteniamo un risultato diverso, possiamo modellarla tramite una variabile aleatoria X . Diremo che la popolazione è descritta dalla variabile aleatoria X . Per studiare le caratteristiche della legge che descrive la variabile aleatoria X , nella parte di statistica descrittiva abbiamo imparato a descrivere alcuni aspetti dei dati di un campione. Un campione è un sottoinsieme di elementi della popolazione su cui misuriamo la variabile. Finché non effettuiamo le misurazioni, un campione di ampiezza n è costituito da n variabili aleatorie X_1, \dots, X_n , tutte identicamente distribuite alla variabile aleatoria che descrive la popolazione. Se il campione è scelto bene, la misurazione effettuata su un elemento del campione non deve influenzare le misurazioni effettuate sugli altri elementi del campione. Sappiamo esprimere bene questo concetto utilizzando il linguaggio della probabilità: le variabili aleatorie X_1, \dots, X_n devono essere indipendenti.

Siamo pronti a fornire la seguente definizione.

DEFINIZIONE 6.1. Consideriamo una popolazione descritta da una variabile aleatoria X . Un *campione casuale* di ampiezza n estratto dalla popolazione è un vettore aleatorio (X_1, \dots, X_n) dove X_1, \dots, X_n sono n variabili aleatorie indipendenti e identicamente distribuite a X . Le componenti x_1, \dots, x_n di una realizzazione $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$ del campione casuale vengono nominati *dati del campione*. □

6.1. Statistiche e stimatori

Forniamo la definizione di statistica campionaria. Le statistiche campionarie sono utilizzate per descrivere alcune grandezze del campione.

DEFINIZIONE 6.2. Sia X_1, \dots, X_n un campione casuale estratto da una popolazione. Una *statistica campionaria* è una variabile aleatoria $H(X) = H(X_1, \dots, X_n)$ dove $H: \mathbb{R}^n \rightarrow \mathbb{R}$ è una funzione. \square

In pratica, una statistica campionaria è una funzione che associa ad ogni realizzazione del campione casuale un numero reale.

Forniamo alcuni esempi di statistiche campionarie.

DEFINIZIONE 6.3. Sia X_1, \dots, X_n un campione casuale. La *media campionaria* è la statistica campionaria definita da

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i.$$

\square

OSSERVAZIONE 6.4. **⚠** Attenzione: la media campionaria è una statistica campionaria, ovvero una variabile aleatoria. È diversa dalla media calcolata sui dati del campione, che è un numero reale associato a una realizzazione del campione casuale. È diverso dal valore atteso, che è un numero reale associato alla variabile aleatoria. \square

DEFINIZIONE 6.5. Sia X_1, \dots, X_n un campione casuale. La *varianza campionaria* è la statistica definita da

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2,$$

dove \bar{X}_n è la media campionaria. \square

OSSERVAZIONE 6.6. **⚠** Attenzione: la varianza campionaria è una statistica campionaria, ovvero una variabile aleatoria. È diversa dalla varianza calcolata sui dati del campione, che è un numero reale associato a una realizzazione del campione casuale. È diverso dalla varianza, che è un numero reale associato alla variabile aleatoria. \square

D'ora in poi ci occuperemo del problema di stimare parametri da cui dipende la legge della variabile aleatoria X che descrive la popolazione. Più precisamente, consideriamo una variabile aleatoria X che descrive la variabile di una popolazione. Supponiamo che X sia descritta da alcuni parametri $\theta \in \Theta$, dove Θ è l'insieme dei possibili parametri della variabile aleatoria X .

Forniamo alcuni esempi di popolazioni descritte da variabili aleatorie con parametri.

ESEMPIO 6.7. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge normale $\mathcal{N}(\mu, \sigma^2)$. I parametri della variabile aleatoria X sono $\theta = (\mu, \sigma^2)$. L'insieme dei possibili parametri è $\Theta = \mathbb{R} \times (0, +\infty)$. \square

ESEMPIO 6.8. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge esponenziale $\text{Exp}(\lambda)$. I parametri della variabile aleatoria X sono $\theta = \lambda$. L'insieme dei possibili parametri è $\Theta = (0, +\infty)$. \square

ESEMPIO 6.9. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge binomiale $B(n, p)$. I parametri della variabile aleatoria X sono $\theta = (n, p)$. L'insieme dei possibili parametri è $\Theta = \mathbb{N} \times (0, 1)$. \square

ESEMPIO 6.10. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge di Poisson $P(\lambda)$. I parametri della variabile aleatoria X sono $\theta = \lambda$. L'insieme dei possibili parametri è $\Theta = (0, +\infty)$. \square

ESEMPIO 6.11. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge Gamma(α, λ). I parametri della variabile aleatoria X sono $\theta = (\alpha, \lambda)$. L'insieme dei possibili parametri è $\Theta = (0, +\infty) \times (0, +\infty)$. \square

Consideriamo una variabile aleatoria X descritta da parametri $\theta \in \Theta$. Spesso vorremo stimare un particolare parametro da cui dipende la popolazione. Per questo motivo considereremo una funzione $h: \Theta \rightarrow \mathbb{R}$ che associa ad ogni θ un particolare parametro $h(\theta)$ che vogliamo stimare.

ESEMPIO 6.12. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge normale $\mathcal{N}(\mu, \sigma^2)$. Vogliamo stimare la media della popolazione. La funzione $h(\mu, \sigma^2) = \mu$ associa ad ogni coppia di parametri il primo parametro, ovvero la media. \square

ESEMPIO 6.13. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge normale $\mathcal{N}(\mu, \sigma^2)$. Vogliamo stimare la varianza della popolazione. La funzione $h(\mu, \sigma^2) = \sigma^2$ associa ad ogni coppia di parametri il secondo parametro, ovvero la varianza. \square

ESEMPIO 6.14. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge esponenziale $\text{Exp}(\lambda)$. Vogliamo stimare la media della popolazione. La funzione $h(\lambda) = \frac{1}{\lambda}$ associa ad ogni parametro il reciproco del parametro, ovvero la media. \square

ESEMPIO 6.15. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge binomiale $B(n, p)$. Vogliamo stimare la media della popolazione. La funzione $h(n, p) = np$ associa ad ogni coppia di parametri il prodotto dei due parametri, ovvero la media. \square

ESEMPIO 6.16. Consideriamo una popolazione descritta da una variabile aleatoria X distribuita con legge Gamma(α, β). Vogliamo stimare la media della popolazione. La funzione $h(\alpha, \lambda) = \frac{\alpha}{\lambda}$ associa ad ogni coppia di parametri il rapporto dei due parametri, ovvero la media. \square

DEFINIZIONE 6.17. Sia X_1, \dots, X_n un campione casuale estratto da una popolazione descritta da una variabile aleatoria X descritta da parametri $\theta \in \Theta$. Sia $h: \Theta \rightarrow \mathbb{R}$ una funzione che associa ad ogni θ il parametro $h(\theta)$ che si vuole stimare. Sia $H(X) = H(X_1, \dots, X_n)$ una statistica campionaria. Uno *stimatore* del parametro $h(\theta)$ è una statistica campionaria $H(X)$ con lo scopo di stimare il parametro $h(\theta)$. Lo stimatore

$H(X)$ è *corretto* se ha valore atteso uguale al parametro che si vuole stimare, ovvero se $\mathbb{E}(H(X)) = h(\theta)$. \square

PROPOSIZIONE 6.18. *La media campionaria è uno stimatore corretto della media della popolazione.*

DIMOSTRAZIONE. Sia X_1, \dots, X_n un campione casuale estratto da una popolazione X con $\mathbb{E}(X) = \mu$. Sia \bar{X}_n la media campionaria. Dimostriamo che $\mathbb{E}(\bar{X}_n) = \mu$. Utilizzando la linearità del valore atteso, otteniamo che

$$\mathbb{E}(\bar{X}_n) = \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{n\mu}{n} = \mu.$$

Questo conclude la dimostrazione. \square

OSSERVAZIONE 6.19. Calcoliamo la varianza della media campionaria. Questo conto sarà fondamentale per alcune considerazioni di statistica inferenziale. Consideriamo X_1, \dots, X_n un campione casuale estratto da una popolazione X con $\mathbb{E}(X) = \mu$ e $\text{Var}(X) = \sigma^2$. Utilizzando il fatto che la varianza scala quadraticamente rispetto a trasformazioni lineari e utilizzando l'indipendenza delle variabili aleatorie, per l'Osservazione 3.68 otteniamo che

$$\begin{aligned} \text{Var}(\bar{X}_n) &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{n\sigma^2}{n^2} \\ &= \frac{\sigma^2}{n}. \end{aligned}$$

In particolare, per la deviazione standard abbiamo che

$$\sigma(\bar{X}_n) = \frac{\sigma}{\sqrt{n}}.$$

Una interpretazione importante di questo conto è la seguente: la media campionaria ha il valore atteso della popolazione μ , ma ha varianza che diventa sempre più piccola all'aumentare dell'ampiezza del campione. Questo vuol dire che più è ampio il campione, più la media campionaria è certa e si concentra sul valore atteso μ . Questa intuizione sarà resa rigorosa nei teoremi limite Teorema 6.22 e Teorema 6.25. \square

PROPOSIZIONE 6.20. *La varianza campionaria è uno stimatore corretto della varianza della popolazione.*

DIMOSTRAZIONE. Sia X_1, \dots, X_n un campione casuale estratto da una popolazione X con $\mathbb{E}(X) = \mu$ e $\text{Var}(X) = \sigma^2$. Sia S_n^2 la varianza campionaria. Dimostriamo che $\mathbb{E}(S_n^2) = \sigma^2$. Utilizziamo la linearità del valore atteso e sviluppiamo il quadrato per

ottenere che

$$\begin{aligned}\mathbb{E}(S_n^2) &= \mathbb{E}\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right) \\ &= \frac{1}{n-1} \sum_{i=1}^n \mathbb{E}(X_i^2 + \bar{X}_n^2 - 2X_i\bar{X}_n) \\ &= \frac{1}{n-1} \sum_{i=1}^n \left(\mathbb{E}(X_i^2) + \mathbb{E}(\bar{X}_n^2) - 2\mathbb{E}(X_i\bar{X}_n)\right).\end{aligned}\tag{6.1}$$

Calcoliamo separatamente i tre valori attesi. Utilizzando la formula per la varianza (3.1) otteniamo che

$$\mathbb{E}(X_i^2) = \text{Var}(X_i) + \mathbb{E}(X_i)^2 = \sigma^2 + \mu^2.\tag{6.2}$$

Per la stessa formula abbiamo che

$$\mathbb{E}(\bar{X}_n^2) = \text{Var}(\bar{X}_n) + \mathbb{E}(\bar{X}_n)^2.$$

Utilizziamo la formula per la varianza della media campionaria ottenuta nell'Osservazione 6.19 per ottenere che $\text{Var}(\bar{X}_n) = \frac{\sigma^2}{n}$. Per la Proposizione 6.18 abbiamo che $\mathbb{E}(\bar{X}_n) = \mu$. Quindi

$$\mathbb{E}(\bar{X}_n^2) = \frac{\sigma^2}{n} + \mu^2.\tag{6.3}$$

Calcoliamo il terzo termine utilizzando la linearità del valore atteso

$$\begin{aligned}\mathbb{E}(X_i\bar{X}_n) &= \mathbb{E}\left(X_i \frac{1}{n} \sum_{j=1}^n X_j\right) = \frac{1}{n} \sum_{j=1}^n \mathbb{E}(X_i X_j) \\ &= \frac{1}{n} \sum_{\substack{j=1 \\ j \neq i}}^n \mathbb{E}(X_i X_j) + \frac{1}{n} \mathbb{E}(X_i^2).\end{aligned}$$

Poiché X_i e X_j sono indipendenti per $i \neq j$, si ha che $\text{Cov}(X_i, X_j) = 0$, ovvero $\mathbb{E}(X_i X_j) = \mathbb{E}(X_i)\mathbb{E}(X_j) = \mu^2$. Inoltre, per la formula della varianza,

$$\mathbb{E}(X_i^2) = \text{Var}(X_i) + \mathbb{E}(X_i)^2 = \sigma^2 + \mu^2.$$

Segue che

$$\mathbb{E}(X_i\bar{X}_n) = \frac{n-1}{n} \mu^2 + \frac{1}{n} \sigma^2 + \frac{1}{n} \mu^2 = \frac{1}{n} \sigma^2 + \mu^2.\tag{6.4}$$

Mettendo insieme (6.1)–(6.2)–(6.3)–(6.4) otteniamo che

$$\begin{aligned}\mathbb{E}(S_n^2) &= \frac{1}{n-1} \sum_{i=1}^n \left(\sigma^2 + \mu^2 + \frac{\sigma^2}{n} + \mu^2 - 2\frac{1}{n} \sigma^2 - 2\mu^2\right) \\ &= \frac{1}{n-1} \sum_{i=1}^n \frac{n-1}{n} \sigma^2 = \sigma^2.\end{aligned}$$

Questo conclude la dimostrazione. □

6.2. Alcune leggi importanti

In questa sezione descriviamo la legge di alcune statistiche importanti che incontreremo spesso nella statistica inferenziale.

Legge normale. Consideriamo una variabile aleatoria X distribuita con legge normale $\mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione. Allora la statistica $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ è distribuita con legge normale standard $\mathcal{N}(0, 1)$.

Infatti, $\sum_{i=1}^n X_i$ è la somma di variabili aleatorie indipendenti distribuite con legge normale $\mathcal{N}(\mu, \sigma^2)$, quindi per la Proposizione 5.14 è distribuita con legge normale $\mathcal{N}(n\mu, n\sigma^2)$. Ricordando il comportamento della varianza rispetto alla moltiplicazione per uno scalare, si veda l'Osservazione 3.60, otteniamo che $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \sim \mathcal{N}(\mu, \frac{\sigma^2}{n})$. Segue che $\bar{X}_n - \mu \sim \mathcal{N}(0, \frac{\sigma^2}{n})$ e quindi $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$.

Legge chi-quadro. Consideriamo una variabile aleatoria X distribuita con legge normale $\mathcal{N}(0, 1)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione. Allora $\frac{(n-1)S_n^2}{\sigma^2}$ è distribuita con legge chi-quadro con $(n-1)$ gradi di libertà $\chi^2(n-1)$.

Non lo dimostriamo, ma possiamo fornire una spiegazione per convincerci della validità di questo risultato. Decomponiamo la varianza campionaria nel seguente modo:

$$\begin{aligned} S_n^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu + \mu - \bar{X}_n)^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu)^2 + 2 \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu)(\mu - \bar{X}_n) + \frac{1}{n-1} \sum_{i=1}^n (\bar{X}_n - \mu)^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu)^2 - 2 \frac{1}{n-1} (\bar{X}_n - \mu) \sum_{i=1}^n (X_i - \mu) + \frac{n}{n-1} (\bar{X}_n - \mu)^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu)^2 - 2 \frac{n}{n-1} (\bar{X}_n - \mu)^2 + \frac{n}{n-1} (\bar{X}_n - \mu)^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \mu)^2 - \frac{n}{n-1} (\bar{X}_n - \mu)^2. \end{aligned}$$

Moltiplichiamo per $\frac{n-1}{\sigma^2}$ e otteniamo che

$$\frac{(n-1)S_n^2}{\sigma^2} = \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 - \left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \right)^2,$$

ovvero

$$\frac{(n-1)S_n^2}{\sigma^2} + \left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \right)^2 = \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2.$$

Studiamo i termini in questa equazione. La variabile aleatoria $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ è distribuita con legge normale standard $\mathcal{N}(0, 1)$ (si veda la sottosezione precedente), quindi per l'Osservazione 5.42, il suo quadrato è distribuito con legge $\chi^2(1)$. Per ogni $i = 1, \dots, n$, la variabile aleatoria $\frac{X_i - \mu}{\sigma}$ è distribuita con legge normale standard $\mathcal{N}(0, 1)$, quindi il suo quadrato è distribuito con legge $\chi^2(1)$. Per l'Osservazione 5.43, segue che la somma di n variabili aleatorie indipendenti distribuite con legge $\chi^2(1)$ è distribuita con legge $\chi^2(n)$, quindi la

variabile aleatoria a sinistra dell'equazione è distribuita con legge $\chi^2(n-1)$. Otteniamo che

$$\frac{(n-1)S_n^2}{\sigma^2} + \underbrace{\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}\right)^2}_{\sim \chi^2(1)} = \underbrace{\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2}_{\sim \chi^2(n)}.$$

Da qui in poi i passaggi non sono rigorosi. Prima di tutto si può dimostrare che \bar{X}_n e S_n^2 sono variabili aleatorie indipendenti. Questo fatto richiede alcuni strumenti che non abbiamo affrontato nel corso.

Dall'indipendenza di \bar{X}_n e S_n^2 segue l'indipendenza di $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ e $\frac{(n-1)S_n^2}{\sigma^2}$. Allora siamo arrivati alla seguente decomposizione:

$$\frac{(n-1)S_n^2}{\sigma^2} + Q_1 = Q_n,$$

dove $Q_1 \sim \chi^2(1)$ e $Q_n \sim \chi^2(n)$ e le variabili aleatorie nel membro a sinistra sono indipendenti. Se consideriamo una $Q_{n-1} \sim \chi^2(n-1)$ indipendente da Q_1 , dall'Osservazione 5.43 otteniamo che

$$Q_{n-1} + Q_1 = Q_n.$$

Si può dimostrare (e non è un fatto banale) che questa decomposizione è unica, quindi necessariamente $\frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Questo risultato è noto in letteratura come Teorema di Cochran.

OSSERVAZIONE 6.21. \clubsuit Abbiamo gli strumenti per dimostrare l'indipendenza tra media campionaria e varianza campionaria quando $n = 2$.

Siano $X_1, X_2 \sim \mathcal{N}(\mu, \sigma^2)$ due variabili aleatorie indipendenti. Dimostriamo che $\bar{X}_2 = \frac{X_1 + X_2}{2}$ e $S_2^2 = (X_1 - \bar{X}_2)^2 + (X_2 - \bar{X}_2)^2$ sono indipendenti.

Riscriviamo la varianza campionaria come

$$S_2^2 = (X_1 - \bar{X}_2)^2 + (X_2 - \bar{X}_2)^2 = \left(X_1 - \frac{X_1 + X_2}{2}\right)^2 + \left(X_2 - \frac{X_1 + X_2}{2}\right)^2 = \frac{(X_1 - X_2)^2}{4}.$$

Chiamiamo

$$Y_1 = X_1 + X_2 \sim \mathcal{N}(2\mu, 2\sigma^2) \quad \text{e} \quad Y_2 = X_1 - X_2 \sim \mathcal{N}(0, 2\sigma^2).$$

Se dimostriamo che Y_1 e Y_2 sono indipendenti, allora \bar{X}_2 e S_2^2 sono indipendenti perché sono funzioni di Y_1 e Y_2 , si veda la Proposizione 3.29. Osserviamo che

$$\begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}}_A \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}, \quad \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \underbrace{\begin{pmatrix} 1/2 & 1/2 \\ 1/2 & -1/2 \end{pmatrix}}_{A^{-1}} \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix}.$$

Questa trasformazione ci permette di calcolare la densità congiunta di (Y_1, Y_2) . Infatti, da un lato abbiamo che

$$\mathbb{P}(\{(Y_1, Y_2) \in I_1 \times I_2\}) = \iint_{I_1 \times I_2} f_{(Y_1, Y_2)}(y_1, y_2) dy_1 dy_2.$$

D'altra parte otteniamo che

$$\begin{aligned}
\mathbb{P}(\{(Y_1, Y_2) \in I_1 \times I_2\}) &= \mathbb{P}(\{A(X_1, X_2)^T \in I_1 \times I_2\}) = \mathbb{P}(\{(X_1, X_2) \in A^{-1}(I_1 \times I_2)\}) \\
&= \iint_{A^{-1}(I_1 \times I_2)} f_{(X_1, X_2)}(x_1, x_2) dx_1 dx_2 \\
&\quad \blacksquare X_1 \text{ e } X_2 \text{ sono indipendenti, per la Proposizione 3.48} \\
&= \iint_{A^{-1}(I_1 \times I_2)} f_{X_1}(x_1) f_{X_2}(x_2) dx_1 dx_2 \\
&\quad \blacksquare \text{ cambio di variabili } \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = A \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \implies \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = A^{-1} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \\
&\quad \blacksquare dy_1 dy_2 = |\det A| dx_1 dx_2 = 2 dx_1 dx_2 \\
&= \frac{1}{2} \iint_{I_1 \times I_2} f_{X_1}\left(\frac{y_1 + y_2}{2}\right) f_{X_2}\left(\frac{y_1 - y_2}{2}\right) dy_1 dy_2 \\
&= \frac{1}{2} \iint_{I_1 \times I_2} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(y_1 + y_2 - \mu)^2}{2\sigma^2}} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(y_1 - y_2 - \mu)^2}{2\sigma^2}} dy_1 dy_2 \\
&= \frac{1}{2} \iint_{I_1 \times I_2} \frac{1}{\sigma^2 2\pi} e^{-\frac{(y_1 - 2\mu + y_2)^2 + (y_1 - 2\mu - y_2)^2}{8\sigma^2}} dy_1 dy_2 \\
&= \frac{1}{2} \iint_{I_1 \times I_2} \frac{1}{\sigma^2 2\pi} e^{-\frac{2(y_1 - 2\mu)^2 + 2y_2^2}{8\sigma^2}} dy_1 dy_2 \\
&= \iint_{I_1 \times I_2} \frac{1}{\sqrt{2\sigma}\sqrt{2\pi}} e^{-\frac{(y_1 - 2\mu)^2}{4\sigma^2}} \frac{1}{\sqrt{2\sigma}\sqrt{2\pi}} e^{-\frac{y_2^2}{4\sigma^2}} dy_1 dy_2 \\
&= \iint_{I_1 \times I_2} f_{Y_1}(y_1) f_{Y_2}(y_2) dy_1 dy_2 \\
&= \int_{I_1} f_{Y_1}(y_1) dy_1 \int_{I_2} f_{Y_2}(y_2) dy_2 \\
&= \mathbb{P}(\{Y_1 \in I_1\}) \mathbb{P}(\{Y_2 \in I_2\}).
\end{aligned}$$

Questo dimostra che Y_1 e Y_2 sono indipendenti. □

Legge t di Student. Consideriamo una variabile aleatoria X distribuita con legge normale $\mathcal{N}(0, 1)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione. Allora la statistica $\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}}$ è distribuita con legge t di Student con $n - 1$ gradi di libertà $t(n - 1)$.

Infatti, poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, abbiamo che $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ e $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n - 1)$. Inoltre, come spiegato nella sezione precedente, si può dimostrare che Z e Q_{n-1} sono indipendenti. Segue che

$$\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \frac{\sigma}{S_n} = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \frac{1}{\sqrt{\frac{(n-1)S_n^2}{\sigma^2}/(n-1)}} = \frac{Z}{\sqrt{Q_{n-1}/(n-1)}} = T_{n-1} \sim t(n-1),$$

dove abbiamo applicato la Proposizione 5.46.

6.3. Teoremi limite

In questa sezione enunciamo due teoremi fondamentali della statistica inferenziale: la legge dei grandi numeri e il teorema del limite centrale. Questi teoremi sono alla base della statistica inferenziale e permettono di fare inferenze sulla popolazione a partire da un campione casuale. Dimostreremo la legge dei grandi numeri, mentre il teorema del limite centrale sarà solo enunciato, poiché la sua dimostrazione richiede strumenti matematici più avanzati.

La legge dei grandi numeri rende rigorosa l'intuizione di cui abbiamo parlato nell'Osservazione 6.19: la media campionaria ha lo stesso valore atteso della popolazione, ma la sua varianza diventa sempre più piccola all'aumentare dell'ampiezza del campione.

TEOREMA 6.22 (Legge dei grandi numeri). *Sia X_1, \dots, X_n, \dots una successione di variabili aleatorie indipendenti con $\mathbb{E}(X_i) = \mu$ e $\text{Var}(X_i) = \sigma^2$. Per ogni $n \geq 1$ sia $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ la media campionaria. Allora, per ogni $\varepsilon > 0$, si ha che*

$$\lim_{n \rightarrow +\infty} \mathbb{P}(\{|\bar{X}_n - \mu| > \varepsilon\}) = 0.$$

Questa convergenza è detta convergenza in probabilità.

DIMOSTRAZIONE. Fissiamo $\varepsilon > 0$. Osserviamo che

$$|\bar{X}_n - \mu| > \varepsilon \iff (\bar{X}_n - \mu)^2 > \varepsilon^2,$$

quindi

$$\mathbb{P}(\{|\bar{X}_n - \mu| > \varepsilon\}) = \mathbb{P}(\{(\bar{X}_n - \mu)^2 > \varepsilon^2\}). \quad (6.5)$$

Introduciamo momentaneamente la variabile aleatoria $Y_n = (\bar{X}_n - \mu)^2$. Osserviamo che¹

$$\mathbb{P}(\{Y_n > \varepsilon^2\}) \leq \frac{1}{\varepsilon^2} \mathbb{E}(Y_n). \quad (6.6)$$

Verifichiamo questa disuguaglianza separatamente nei casi in cui Y_n è una variabile discreta o continua. Nel caso in cui la variabile aleatoria Y_n è discreta, allora, usando il fatto che Y_n ha range nei positivi

$$\begin{aligned} \mathbb{P}(\{Y_n > \varepsilon^2\}) &= \sum_{\substack{y \in R(Y_n) \\ y > \varepsilon^2}} \mathbb{P}(\{Y_n = y\}) = \sum_{\substack{y \in R(Y_n) \\ y > \varepsilon^2}} \frac{\varepsilon^2}{\varepsilon^2} \mathbb{P}(\{Y_n = y\}) \\ &\leq \frac{1}{\varepsilon^2} \sum_{\substack{y \in R(Y_n) \\ y > \varepsilon^2}} y \mathbb{P}(\{Y_n = y\}) \leq \frac{1}{\varepsilon^2} \sum_{y \in R(Y_n)} y \mathbb{P}(\{Y_n = y\}) \\ &= \frac{1}{\varepsilon^2} \mathbb{E}(Y_n). \end{aligned}$$

¹Questa disuguaglianza è nota in letteratura come *disuguaglianza di Markov*.

Nel caso in cui la variabile aleatoria Y_n è continua con densità f_{Y_n} , allora, usando il fatto che Y_n ha range nei positivi

$$\begin{aligned}\mathbb{P}(\{Y_n > \varepsilon^2\}) &= \int_{\varepsilon^2}^{+\infty} f_{Y_n}(y) \, dy = \int_{\varepsilon^2}^{+\infty} \frac{\varepsilon^2}{\varepsilon^2} f_{Y_n}(y) \, dy \\ &\leq \frac{1}{\varepsilon^2} \int_{\varepsilon^2}^{+\infty} y f_{Y_n}(y) \, dy \leq \frac{1}{\varepsilon^2} \int_0^{+\infty} y f_{Y_n}(y) \, dy \\ &= \frac{1}{\varepsilon^2} \mathbb{E}(Y_n).\end{aligned}$$

Dalla disuguaglianza (6.6) e da (6.5) segue che

$$\mathbb{P}(\{|\bar{X}_n - \mu| \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \mathbb{E}((\bar{X}_n - \mu)^2).$$

Ricordiamo che, per la Proposizione 6.18, la media campionaria \bar{X}_n è uno stimatore corretto della media della popolazione, ovvero $\mathbb{E}(\bar{X}_n) = \mu$. Quindi

$$\text{Var}(\bar{X}_n) = \mathbb{E}((\bar{X}_n - \mathbb{E}(\bar{X}_n))^2) = \mathbb{E}((\bar{X}_n - \mu)^2).$$

Segue che²

$$\mathbb{P}(\{|\bar{X}_n - \mu| \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \text{Var}(\bar{X}_n).$$

Abbiamo calcolato la varianza della media campionaria nell'Osservazione 6.19, ottenendo che $\text{Var}(\bar{X}_n) = \frac{\sigma^2}{n}$. Concludiamo che

$$\mathbb{P}(\{|\bar{X}_n - \mu| \geq \varepsilon\}) \leq \frac{\sigma^2}{n\varepsilon^2}.$$

La tesi segue passando al limite per $n \rightarrow +\infty$. □

OSSERVAZIONE 6.23 (Interpretazione frequentista della probabilità). Consideriamo uno spazio di probabilità $(\Omega, \mathcal{F}, \mathbb{P})$ e un evento $A \in \mathcal{F}$. La probabilità $\mathbb{P}(A)$ è spesso interpretata come la frequenza relativa di A in un numero grande di esperimenti ripetuti. Questa è l'interpretazione frequentista della probabilità ed è dovuta alla legge dei grandi numeri. Consideriamo infatti la variabile aleatoria indicatrice X dell'evento A , definita come

$$X(\omega) = \begin{cases} 1 & \text{se } \omega \in A \\ 0 & \text{se } \omega \notin A. \end{cases}$$

Allora $X \sim \text{Be}(p)$ con $p = \mathbb{P}(A)$. In particolare, $\mathbb{E}(X) = p$. Supponiamo di fare n esperimenti ripetuti indipendenti e di controllare per ogni esperimento se l'evento A si è verificato. In pratica, stiamo considerando un campione casuale di ampiezza n con X_1, \dots, X_n indipendenti e identicamente distribuite a X . Per la legge dei grandi numeri, la media campionaria \bar{X}_n converge in probabilità al valore atteso p della variabile aleatoria X . Tuttavia \bar{X}_n rappresenta la frequenza relativa dell'evento A negli n esperimenti ripetuti, quindi

$$\frac{\text{numero di esperimenti in cui si è verificato } A}{\text{numero di esperimenti}} \rightarrow p = \mathbb{P}(A),$$

per $n \rightarrow +\infty$. □

²Questa disuguaglianza è nota in letteratura come *disuguaglianza di Chebyshev*.

■ Link a slide animata in cui vengono generati molti esiti di un esperimento casuale per approssimare il numero π . Questo tipo di simulazioni per stimare le probabilità sono alla base del Metodo Monte Carlo. <https://orlandopoliba.github.io/Manim-ProbStatPoliba/LLN/LLN.html>

OSSERVAZIONE 6.24 (Fallacia dello scommettitore). ⚠ Attenzione: a volte la legge dei grandi numeri viene interpretata in modo errato, affermando che se un evento non si è verificato per un lungo periodo in prove indipendenti, allora è più probabile che si verifichi in futuro perché la media campionaria deve essere bilanciata. Questa interpretazione è del tutto sbagliata.

Abbiamo imparato a descrivere le prove ripetute indipendenti con la legge geometrica. Se X è la variabile aleatoria che descrive la prima volta in cui si verifica un evento A , allora $X \sim \text{Geo}(p)$ con $p = \mathbb{P}(A)$. Sappiamo che X gode della proprietà dell'assenza di memoria, si veda la Proposizione 4.36.

La legge dei grandi numeri non esclude che un evento possa non verificarsi per un lungo periodo. \square




FIGURA 6.1. A sinistra: Jarl Waldemar Lindeberg (1876-1932).^a Al centro: Alan Turing (1912-1954).^b A destra: Paul Pierre Lévy (1886-1971).^c Hanno dimostrato indipendentemente il Teorema del Limite Centrale nella sua versione più nota, ovvero il Teorema 6.25.

^aFonte dell'immagine: <https://expo.oscapps.jyu.fi/s/minerva/item/57144>.

^bFonte dell'immagine: [https://commons.wikimedia.org/wiki/File:Alan_Turing_\(1912-1954\)_in_1936_at_Princeton_University.jpg](https://commons.wikimedia.org/wiki/File:Alan_Turing_(1912-1954)_in_1936_at_Princeton_University.jpg).

^cFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Paul_Pierre_Lévy_1886-1971.jpg.

Per la legge dei grandi numeri sappiamo che la media campionaria \bar{X}_n tende a concentrarsi attorno al valore atteso μ della popolazione all'aumentare dell'ampiezza del campione. Tuttavia, non sappiamo quanto velocemente avviene questa convergenza. Possiamo studiare l'approssimazione in modo più preciso. La media campionaria resta una variabile aleatoria, quindi possiamo chiederci quanto sia probabile che la media campionaria si discosti dal valore atteso della popolazione e come cambia questa probabilità all'aumentare dell'ampiezza del campione.

■ Link a slide animata in cui viene mostrato un istogramma delle densità di frequenze relative per la media campionaria \bar{X}_n calcolata su un campione casuale di ampiezza $n = 10$: <https://orlandopoliba.github.io/Manim-ProbStatPoliBA/CLT/CLT.html>.

La risposta a questa domanda è il Teorema del Limite Centrale, uno dei risultati più importanti della statistica inferenziale e, più in generale, della matematica. È un risultato sorprendente: esiste una legge universale che descrive il comportamento della media campionaria di un campione casuale estratto da una popolazione qualsiasi. Questo teorema è alla base di molte applicazioni pratiche della statistica inferenziale ed è il motivo per cui la distribuzione normale è così importante.

TEOREMA 6.25 (Teorema del Limite Centrale). *Sia X_1, \dots, X_n, \dots una successione di variabili aleatorie indipendenti e identicamente distribuite con $\mathbb{E}(X_i) = \mu$ e $\text{Var}(X_i) = \sigma^2$. Per ogni $n \geq 1$ sia $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ la media campionaria del campione casuale X_1, \dots, X_n . Allora*

$$\lim_{n \rightarrow +\infty} \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq z\right\}\right) = \mathbb{P}(\{Z \leq z\}), \quad \text{per ogni } z \in \mathbb{R},$$

dove $Z \sim \mathcal{N}(0, 1)$.

Questa convergenza è detta convergenza in distribuzione o convergenza in legge.

(Non dimostriamo il Teorema del Limite Centrale).

OSSERVAZIONE 6.26. In breve, il Teorema del Limite Centrale stabilisce che la media campionaria \bar{X}_n è distribuita approssimativamente come una variabile aleatoria normale $\mathcal{N}(\mu, \frac{\sigma^2}{n})$ per n grande. Riterremo buona questa approssimazione già per $n \geq 30$. Osserviamo però che più è grande n , più l'approssimazione è precisa e più la media campionaria si concentra attorno al valore atteso della popolazione, poiché la varianza della media campionaria diminuisce all'aumentare di n . Tuttavia, ciò non esclude che la media campionaria possa discostarsi dal valore atteso della popolazione. Il Teorema del Limite Centrale quantifica la probabilità che ciò accada. \square

ESEMPIO 6.27 (Approssimazione della legge binomiale con la legge normale). Consideriamo una variabile aleatoria distribuita con legge binomiale $X \sim B(n, p)$ con n grande. Possiamo pensare $X = X_1 + \dots + X_n$ con $X_i \sim \text{Be}(p)$ indipendenti. Supponiamo di dover calcolare

$$\mathbb{P}(\{h \leq X \leq k\}) = \sum_{j=h}^k \binom{n}{j} p^j (1-p)^{n-j}$$

ma che il calcolo esplicito del membro a destra sia troppo dispendioso senza un calcolatore. Poiché la variabile aleatoria X è discreta, si ha che³

$$\mathbb{P}(\{h \leq X \leq k\}) = \mathbb{P}(\{h - 0.5 < X < k + 0.5\}).$$

³Questa *correzione di continuità* rende l'approssimazione più precisa. Tiene conto del fatto che si sta passando da una variabile discreta a una continua.




FIGURA 6.2. A sinistra: Abraham de Moivre (1667-1754).^a A destra: Pierre-Simon Laplace (1749-1827).^b Hanno formulato una delle prime versioni del Teorema del Limite Centrale, mostrando l'approssimazione della distribuzione binomiale con la distribuzione normale.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Abraham_de_moivre.jpg

^bFonte dell'immagine: https://commons.wikimedia.org/wiki/File:P_S_Laplace.jpg

Osserviamo che $\frac{1}{n}X = \bar{X}_n$ è la media campionaria del campione casuale $X_1, \dots, X_n \sim \text{Be}(p)$. La varianza della popolazione è $\text{Var}(X_i) = p(1-p)$. Per il Teorema 6.25 otteniamo che $Z \sim \mathcal{N}(0, 1)$ è una buona approssimazione di $\frac{\bar{X}_n - p}{\sqrt{p(1-p)/n}}$, quindi

$$\begin{aligned} \mathbb{P}(\{h - 0.5 < X < k + 0.5\}) &= \mathbb{P}\left(\left\{\frac{h - 0.5}{n} < \bar{X}_n < \frac{k + 0.5}{n}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{h - 0.5 - np}{n} < \bar{X}_n - p < \frac{k + 0.5 - np}{n}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{h - 0.5 - np}{\sqrt{np(1-p)}} < \frac{\bar{X}_n - p}{\sqrt{p(1-p)/n}} < \frac{k + 0.5 - np}{\sqrt{np(1-p)}}\right\}\right) \\ &\simeq \mathbb{P}\left(\left\{\frac{h - 0.5 - np}{\sqrt{np(1-p)}} < Z < \frac{k + 0.5 - np}{\sqrt{np(1-p)}}\right\}\right). \end{aligned}$$

In conclusione,

$$\mathbb{P}(\{h - 0.5 < X < k + 0.5\}) \simeq \mathbb{P}\left(\left\{\frac{h - 0.5 - np}{\sqrt{np(1-p)}} < Z < \frac{k + 0.5 - np}{\sqrt{np(1-p)}}\right\}\right).$$

Questa approssimazione è già ritenuta buona quando

$$np > 5, \quad n(1-p) > 5.$$

□

► Si consiglia di guardare il video del canale di divulgazione 3Blue1Brown sul Teorema del Limite Centrale. https://www.youtube.com/watch?v=zeJD6dqJ51o&ab_channel=3Blue1Brown

CAPITOLO 7

Intervalli di confidenza

Contenuti

7.1. Definizioni di intervalli di confidenza	165
7.2. Calcolo di intervalli di confidenza	167
7.2.1. Popolazione normale, μ incognita, σ^2 nota: stima di μ	167
7.2.1.1. IC bilaterale per μ	168
7.2.1.2. Limite di confidenza inferiore per μ	169
7.2.1.3. Limite di confidenza superiore per μ	169
7.2.2. Esercizi	170
7.2.3. Popolazione normale, μ incognita, σ^2 incognita: stima di σ^2	171
7.2.3.1. IC bilaterale per σ^2	171
7.2.3.2. Limite di confidenza inferiore per σ^2	173
7.2.3.3. Limite di confidenza superiore per σ^2	174
7.2.4. Esercizi	174
7.2.5. Popolazione normale, μ incognita, σ^2 incognita: stima di μ	175
7.2.5.1. IC bilaterale per μ	175
7.2.5.2. Limite di confidenza inferiore per μ	176
7.2.5.3. Limite di confidenza superiore per μ	177
7.2.6. Esercizi	178
7.2.7. Campione numeroso, μ incognita, σ^2 nota: stima di μ	178
7.2.7.1. IC bilaterale per μ	178
7.2.7.2. Limite di confidenza inferiore per μ	179
7.2.7.3. Limite di confidenza superiore per μ	180
7.2.8. Esercizi	181

7.1. Definizioni di intervalli di confidenza

Iniziamo a occuparci del problema di stimare i parametri di una popolazione. Abbiamo fornito la definizione di stimatore corretto. Gli stimatori corretti possono essere utilizzati per fornire stime puntuali dei parametri di una popolazione. Tuttavia le stime puntuali non sono sufficienti per valutare la qualità della stima. Per questo motivo si introducono gli intervalli di confidenza, che permettono di quantificare la precisione della stima.

DEFINIZIONE 7.1. Si consideri una popolazione distribuita con la legge di una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$. Supponiamo che X dipenda da parametri $\theta \in \Theta$. Sia $h: \Theta \rightarrow \mathbb{R}$ una funzione ($h(\theta)$ è il parametro che si vuole stimare). Sia X_1, \dots, X_n un campione casuale estratto dalla popolazione. Sia $\beta \in (0, 1)$. Un *intervallo di confidenza bilaterale* per $h(\theta)$

con *livello di confidenza* β è un intervallo $[U_n, V_n]$ dove gli estremi U_n e V_n sono statistiche

$$U_n = u_n(X_1, \dots, X_n), \quad V_n = v_n(X_1, \dots, X_n),$$

tali che

$$\mathbb{P}(\{U_n \leq h(\theta) \leq V_n\}) = \beta.$$

Se $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$ sono i dati osservati del campione casuale, le realizzazioni delle variabili aleatorie U_n e V_n sui dati osservati

$$u_n = u_n(x_1, \dots, x_n), \quad v_n = v_n(x_1, \dots, x_n),$$

vengono detti *estremi calcolati sui dati del campione* e $[u_n, v_n]$ è un *intervallo di confidenza calcolato sui dati del campione*. \square

⚠ **Attenzione:** se $[u_n, v_n]$ è un intervallo di confidenza calcolato sui dati del campione, allora u_n e v_n sono numeri reali, quindi l'affermazione "la probabilità che $h(\theta)$ appartenga all'intervallo $[u_n, v_n]$ è β " non ha senso, in quanto $h(\theta)$, u_n , v_n sono numeri reali e non variabili aleatorie. Il parametro $h(\theta)$ appartiene a $[u_n, v_n]$ oppure non appartiene a $[u_n, v_n]$. Non si può parlare di probabilità in questo contesto.

La confidenza misura il seguente fenomeno, giustificato dalla legge dei grandi numeri: se si ripete tante volte l'esperimento di estrarre un campione casuale dalla popolazione e si calcola sui dati un intervallo di confidenza $[u_n, v_n]$ per $h(\theta)$ con livello di confidenza β , allora la proporzione di volte in cui $h(\theta)$ appartiene all'intervallo $[u_n, v_n]$ approssima β al crescere del numero di ripetizioni dell'esperimento.

DEFINIZIONE 7.2. Si consideri una popolazione distribuita con la legge di una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$. Supponiamo che X dipenda da parametri $\theta \in \Theta$. Sia $h: \Theta \rightarrow \mathbb{R}$ una funzione ($h(\theta)$ è il parametro che si vuole stimare). Sia X_1, \dots, X_n un campione casuale estratto dalla popolazione. Sia $\beta \in (0, 1)$. Un *intervallo di confidenza unilaterale destro* per $h(\theta)$ con *livello di confidenza* β è un intervallo $[U_n, +\infty)$ dove l'estremo U_n , detto *limite inferiore di confidenza*, è una statistica

$$U_n = u_n(X_1, \dots, X_n),$$

tale che

$$\mathbb{P}(\{U_n \leq h(\theta)\}) = \beta.$$

Se $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$ sono i dati osservati del campione casuale, la realizzazione della variabile aleatoria U_n sui dati osservati

$$u_n = u_n(x_1, \dots, x_n),$$

viene detto *limite inferiore di confidenza calcolato sui dati del campione* e $[u_n, +\infty)$ è un *intervallo di confidenza unilaterale destro calcolato sui dati del campione*. \square

DEFINIZIONE 7.3. Si consideri una popolazione distribuita con la legge di una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$. Supponiamo che X dipenda da parametri $\theta \in \Theta$. Sia $h: \Theta \rightarrow \mathbb{R}$ una funzione ($h(\theta)$ è il parametro che si vuole stimare). Sia X_1, \dots, X_n un campione casuale estratto dalla popolazione. Sia $\beta \in (0, 1)$. Un *intervallo di confidenza unilaterale*

sinistro per $h(\theta)$ con livello di confidenza β è un intervallo $(-\infty, V_n]$ dove l'estremo V_n , detto *limite superiore di confidenza*, è una statistica

$$V_n = v_n(X_1, \dots, X_n),$$

tale che

$$\mathbb{P}(\{h(\theta) \leq V_n\}) = \beta.$$

Se $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$ sono i dati osservati del campione casuale, la realizzazione della variabile aleatoria V_n sui dati osservati

$$v_n = v_n(x_1, \dots, x_n),$$

viene detto *limite superiore di confidenza calcolato sui dati del campione* e $[v_n, +\infty)$ è un *intervallo di confidenza unilaterale sinistro calcolato sui dati del campione*. \square

Abbrevieremo “intervallo di confidenza” con IC.




FIGURA 7.1. *xkcd* 2440. EPISTEMIC UNCERTAINTY. Credits: <https://xkcd.com/2440/>

7.2. Calcolo di intervalli di confidenza

In questa sezione mostriamo come calcolare gli intervalli di confidenza a seconda della distribuzione della popolazione e del parametro da stimare.

7.2.1. Popolazione normale, μ incognita, σ^2 nota: stima di μ . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione. Supponiamo che σ^2 sia nota (es.: si sa *a priori* che $\sigma^2 = 1$).

7.2.1.1. *IC bilaterale per μ* . Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq Z \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &= 1 - \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) - \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha.$$

Decidiamo di equipartire α :

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}. \quad (7.1)$$

Definiamo $z_{\alpha/2}$ come il punto tale che

$$\mathbb{P}(\{Z \geq z_{\alpha/2}\}) = \frac{\alpha}{2}.$$




FIGURA 7.2. Definizione di $z_{\alpha/2}$ e di $-z_{\alpha/2}$ (per simmetria).

Scegliendo

$$\begin{aligned} \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}} = z_{\alpha/2} &\implies U_n = \bar{X}_n - \frac{\sigma}{\sqrt{n}} z_{\alpha/2}, \\ \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} = -z_{\alpha/2} &\implies V_n = \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_{\alpha/2}, \end{aligned}$$

si ottiene (7.1). In conclusione

$$\left[\bar{X}_n - \frac{\sigma}{\sqrt{n}} z_{\alpha/2}, \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right]$$

è un intervallo di confidenza bilaterale per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.1.2. *Limite di confidenza inferiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{Z \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.2)$$

Definiamo z_α come il punto tale che

$$\mathbb{P}(\{Z \geq z_\alpha\}) = \alpha.$$




FIGURA 7.3. Definizione di z_α .

Scegliendo

$$\frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}} = z_\alpha \implies U_n = \bar{X}_n - \frac{\sigma}{\sqrt{n}} z_\alpha,$$

si ottiene (7.2). In conclusione

$$\left[\bar{X}_n - \frac{\sigma}{\sqrt{n}} z_\alpha, +\infty\right)$$

è un intervallo di confidenza unilaterale destro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.1.3. *Limite di confidenza superiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{\mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{\mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq Z\right\}\right) = 1 - \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.3)$$

Definiamo z_α come il punto tale che

$$\mathbb{P}(\{Z \geq z_\alpha\}) = \alpha.$$




FIGURA 7.4. Definizione di $-z_\alpha$.

Scegliendo

$$\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} = -z_\alpha \implies V_n = \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_\alpha,$$

si ottiene (7.3). In conclusione

$$\left(-\infty, \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_\alpha\right]$$

è un intervallo di confidenza unilaterale sinistro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.2. Esercizi. Qui di seguito sono riportati alcuni esercizi per verificare la comprensione degli argomenti trattati.

ESERCIZIO 7.4. Si desidera una stima dell'intervallo di confidenza per il guadagno in un circuito su un dispositivo a semiconduttore. Assumiamo che il guadagno abbia distribuzione normale con deviazione standard 20.

- (1) Trovare un intervallo di confidenza al 95% per la media μ quando l'ampiezza del campione è 10 e la media calcolata sul campione è 1000.
- (2) Trovare un intervallo di confidenza al 95% per la media μ quando l'ampiezza del campione è 25 e la media calcolata sul campione è 1000.

- (3) Trovare un intervallo di confidenza al 99% per la media μ quando l'ampiezza del campione è 10 e la media calcolata sul campione è 1000.
- (4) Trovare un intervallo di confidenza al 99% per la media μ quando l'ampiezza del campione è 25 e la media calcolata sul campione è 1000.

□

ESERCIZIO 7.5. La norma ASTM E23 definisce metodi di prova standard per le prove di impatto su barre dentellate di materiali metallici. La tecnica Charpy V-notch (CVN) misura l'energia d'urto assorbita e viene spesso utilizzata per determinare se un materiale subisce o meno una transizione da duttile a fragile al diminuire della temperatura. Dieci misurazioni dell'energia d'urto assorbita (in J) su provini di acciaio A238 a 60°C sono le seguenti:

64.1 64.7 64.5 64.6 64.5 64.3 64.6 64.8 64.2 64.3.

Si supponga che l'energia d'impatto abbia distribuzione normale con deviazione standard $1J$.

- (1) Trovare un intervallo di confidenza al 95% per l'energia di impatto media.
- (2) Trovare un limite di confidenza superiore al 99% per l'energia di impatto media.

□

ESERCIZIO 7.6. Sono stati prelevati 100 campioni casuali di acqua da un lago d'acqua dolce ed è stata misurata la concentrazione di calcio (milligrammi per litro). Un intervallo di confidenza al 95% sulla concentrazione media di calcio è $0.49 \leq \mu \leq 0.82$.

- (1) Un intervallo di confidenza al 99% calcolato dagli stessi dati del campione sarebbe stato più o meno ampio?
- (2) Considera la seguente affermazione: C'è una probabilità del 95% che μ sia compreso tra 0.49 e 0.82. Questa affermazione è corretta? Motiva la risposta.
- (3) Considera la seguente affermazione: Se 100 campioni casuali di acqua sono prelevati dal lago e viene calcolato un intervallo di confidenza al 95% per μ e questo processo viene ripetuto 1000 volte, circa 950 degli IC conterranno il vero valore di μ . Questa affermazione è corretta? Motiva la risposta.

□

7.2.3. Popolazione normale, μ incognita, σ^2 incognita: stima di σ^2 . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione.

7.2.3.1. *IC bilaterale per σ^2 .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \sigma^2 \leq V_n\}).$$

Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \sigma^2 \leq V_n\}) = \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{V_n} \leq \frac{(n-1)S_n^2}{\sigma^2} \leq \frac{(n-1)S_n^2}{U_n}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{V_n} \leq Q_{n-1} \leq \frac{(n-1)S_n^2}{U_n}\right\}\right) \\ &= 1 - \mathbb{P}\left(\left\{Q_{n-1} < \frac{(n-1)S_n^2}{V_n}\right\}\right) - \mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Q_{n-1} < \frac{(n-1)S_n^2}{V_n}\right\}\right) + \mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right) = 1 - \beta = \alpha.$$

Decidiamo di equipartire α :

$$\mathbb{P}\left(\left\{Q_{n-1} < \frac{(n-1)S_n^2}{V_n}\right\}\right) = \mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right) = \frac{\alpha}{2}, \quad (7.4)$$

da cui

$$\mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right) = \frac{\alpha}{2}, \quad \mathbb{P}\left(\left\{Q_{n-1} \geq \frac{(n-1)S_n^2}{V_n}\right\}\right) = 1 - \frac{\alpha}{2}.$$

Definiamo $\chi_{n-1, \alpha/2}^2$ e $\chi_{n-1, 1-\alpha/2}^2$ come i punti tali che

$$\mathbb{P}(\{Q_{n-1} \geq \chi_{n-1, \alpha/2}^2\}) = \frac{\alpha}{2}, \quad \mathbb{P}(\{Q_{n-1} \geq \chi_{n-1, 1-\alpha/2}^2\}) = 1 - \frac{\alpha}{2}.$$




FIGURA 7.5. Definizione di $\chi_{n-1, \alpha/2}^2$ e $\chi_{n-1, 1-\alpha/2}^2$.

Scegliendo

$$\begin{aligned} \frac{(n-1)S_n^2}{U_n} = \chi_{n-1, \alpha/2}^2 &\implies U_n = \frac{(n-1)S_n^2}{\chi_{n-1, \alpha/2}^2}, \\ \frac{(n-1)S_n^2}{V_n} = \chi_{n-1, 1-\alpha/2}^2 &\implies V_n = \frac{(n-1)S_n^2}{\chi_{n-1, 1-\alpha/2}^2}, \end{aligned}$$

si ottiene (7.4). In conclusione

$$\left[\frac{(n-1)S_n^2}{\chi_{n-1, \alpha/2}^2}, \frac{(n-1)S_n^2}{\chi_{n-1, 1-\alpha/2}^2} \right]$$

è un intervallo di confidenza bilaterale per σ^2 con livello di confidenza $\beta = 1 - \alpha$.

7.2.3.2. *Limite di confidenza inferiore per σ^2 .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \sigma^2\}).$$

Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \sigma^2\}) = \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} \leq \frac{(n-1)S_n^2}{U_n}\right\}\right) = \mathbb{P}\left(\left\{Q_{n-1} \leq \frac{(n-1)S_n^2}{U_n}\right\}\right) \\ &= 1 - \mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Q_{n-1} > \frac{(n-1)S_n^2}{U_n}\right\}\right) = 1 - \beta = \alpha. \quad (7.5)$$

Definiamo $\chi_{n-1, \alpha}^2$ come il punto tale che

$$\mathbb{P}(\{Q_{n-1} \geq \chi_{n-1, \alpha}^2\}) = \alpha.$$




FIGURA 7.6. Definizione di $\chi_{n-1, \alpha}^2$.

Scegliendo

$$\frac{(n-1)S_n^2}{U_n} = \chi_{n-1, \alpha}^2 \implies U_n = \frac{(n-1)S_n^2}{\chi_{n-1, \alpha}^2},$$

si ottiene (7.5). In conclusione

$$\left[\frac{(n-1)S_n^2}{\chi_{n-1, \alpha}^2}, +\infty \right)$$

è un intervallo di confidenza unilaterale destro per σ^2 con livello di confidenza $\beta = 1 - \alpha$.

7.2.3.3. *Limite di confidenza superiore per σ^2 .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{\sigma^2 \leq V_n\}).$$

Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{\sigma^2 \leq V_n\}) = \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{V_n} \leq \frac{(n-1)S_n^2}{\sigma^2}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{V_n} \leq Q_{n-1}\right\}\right). \end{aligned} \quad (7.6)$$

Definiamo $\chi_{n-1, \beta}^2$ come il punto tali che

$$\mathbb{P}(\{Q_{n-1} \geq \chi_{n-1, \beta}^2\}) = \beta.$$




FIGURA 7.7. Definizione di $\chi_{n-1, \beta}^2$.

Scegliendo

$$\frac{(n-1)S_n^2}{V_n} = \chi_{n-1, \beta}^2 \implies V_n = \frac{(n-1)S_n^2}{\chi_{n-1, \beta}^2},$$

si ottiene (7.6). In conclusione

$$\left(0, \frac{(n-1)S_n^2}{\chi_{n-1, \beta}^2}\right]$$

è un intervallo di confidenza unilaterale sinistro per σ^2 con livello di confidenza $\beta = 1 - \alpha$.

7.2.4. Esercizi. Qui di seguito sono riportati alcuni esercizi per verificare la comprensione degli argomenti trattati.

ESERCIZIO 7.7. Una riempitrice automatica viene utilizzata per riempire bottiglie con detersivo liquido. Un campione casuale di 20 bottiglie determina una deviazione standard campionaria del volume di riempimento di 0.4524 (ml). Se la variazione del volume di riempimento è eccessiva, una proporzione inaccettabile di bottiglie sarà riempita troppo o troppo poco. Assumiamo che il volume di riempimento sia distribuito normalmente. Determinare un limite di confidenza superiore del 95%. \square

ESERCIZIO 7.8. Il contenuto di zucchero dello sciroppo nelle pesche sciropate ha distribuzione normale. Un campione casuale di 10 lattine produce una deviazione standard campionaria di 4.8 milligrammi. Trova un intervallo di confidenza bilaterale al 90% per la deviazione standard σ . \square

7.2.5. Popolazione normale, μ incognita, σ^2 incognita: stima di μ . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione.

7.2.5.1. *IC bilaterale per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $T_{n-1} = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \sim t(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} \leq T_{n-1} \leq \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) \\ &= 1 - \mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right) - \mathbb{P}\left(\left\{T_{n-1} > \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{T_{n-1} > \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha.$$

Decidiamo di equipartire α :

$$\mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}. \quad (7.7)$$

Definiamo $t_{n-1, \alpha/2}$ come il punto tale che

$$\mathbb{P}(\{T_{n-1} \geq t_{n-1, \alpha/2}\}) = \frac{\alpha}{2}.$$




FIGURA 7.8. Definizione di $t_{n-1, \alpha/2}$.

Scegliendo

$$\frac{\bar{X}_n - U_n}{S_n/\sqrt{n}} = t_{n-1,\alpha/2} \implies U_n = \bar{X}_n - \frac{S_n}{\sqrt{n}}t_{n-1,\alpha/2},$$

$$\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} = -t_{n-1,\alpha/2} \implies V_n = \bar{X}_n + \frac{S_n}{\sqrt{n}}t_{n-1,\alpha/2},$$

si ottiene (7.7). In conclusione

$$\left[\bar{X}_n - \frac{S_n}{\sqrt{n}}t_{n-1,\alpha/2}, \bar{X}_n + \frac{S_n}{\sqrt{n}}t_{n-1,\alpha/2} \right]$$

è un intervallo di confidenza bilaterale per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.5.2. *Limite di confidenza inferiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $T_{n-1} = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \sim t(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{T_{n-1} \leq \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) = 1 - \mathbb{P}\left(\left\{T_{n-1} > \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{T_{n-1} > \frac{\bar{X}_n - U_n}{S_n/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.8)$$

Definiamo $t_{n-1,\alpha}$ come il punto tale che

$$\mathbb{P}(\{T_{n-1} \geq t_{n-1,\alpha}\}) = \alpha.$$




FIGURA 7.9. Definizione di $t_{n-1,\alpha}$.

Scegliendo

$$\frac{\bar{X}_n - U_n}{S_n/\sqrt{n}} = t_{n-1,\alpha} \implies U_n = \bar{X}_n - \frac{S_n}{\sqrt{n}}t_{n-1,\alpha},$$

si ottiene (7.8). In conclusione

$$\left[\bar{X}_n - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}, +\infty \right)$$

è un intervallo di confidenza unilaterale destro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.5.3. *Limite di confidenza superiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{\mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Per stimare σ^2 sfrutteremo lo stimatore varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$. Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ sono indipendenti, $T_{n-1} = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \sim t(n-1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{\mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}}\right\}\right) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} \leq T_{n-1}\right\}\right) = 1 - \mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{T_{n-1} < \frac{\bar{X}_n - V_n}{S_n/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.9)$$

Definiamo $t_{n-1, \alpha}$ come il punto tale che

$$\mathbb{P}(\{T_{n-1} \geq t_{n-1, \alpha}\}) = \alpha.$$




FIGURA 7.10. Definizione di $-t_{n-1, \alpha}$.

Scegliendo

$$\frac{\bar{X}_n - V_n}{S_n/\sqrt{n}} = -t_{n-1, \alpha} \implies V_n = \bar{X}_n + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha},$$

si ottiene (7.9). In conclusione

$$\left(-\infty, \bar{X}_n + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right]$$

è un intervallo di confidenza unilaterale sinistro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.6. Esercizi. Qui di seguito sono riportati alcuni esercizi per verificare la comprensione degli argomenti trattati.

ESERCIZIO 7.9. Un articolo sulla rivista *Journal in Materials Engineering* (1989, Vol. II, No. 4, pp. 275–281) descrive i risultati dei test di adesione a trazione su 22 provini di lega U-700. Il carico nel punto di rottura del provino è il seguente (in megapascal):

19.8 10.1 15.4 18.5 11.4 14.1 19.5 8.8 14.9 7.5 7.9
12.7 15.4 15.4 11.9 11.4 17.6 16.7 15.8 13.6 11.9 11.4

Si supponga che il carico nel punto di rottura abbia distribuzione normale. Trovare un intervallo di confidenza per μ al 95%. \square

ESERCIZIO 7.10. Un ingegnere ricercatore per un produttore di pneumatici sta studiando la durata di uno pneumatico per una nuova miscela di gomma. Ha costruito 16 pneumatici e li ha testati fino al termine del loro ciclo di vita in un test su strada. La media campionaria e la deviazione standard campionaria misurate sono 60 139.7 e 3 645.94 chilometri. Si supponga che la vita di uno pneumatico abbia distribuzione normale. Trovare un intervallo di confidenza al 95% sulla vita media dello pneumatico. \square

ESERCIZIO 7.11. Lo spessore delle pareti di 25 bottiglie di vetro da 2 litri ha distribuzione normale ed è stato misurato da un tecnico del controllo di qualità. La media campionaria è 4.05 millimetri e la deviazione standard campionaria è 0.08 millimetri. Trovare un limite di confidenza inferiore del 95% per lo spessore medio della parete. \square

7.2.7. Campione numeroso, μ incognita, σ^2 nota: stima di μ . Consideriamo una popolazione $X: \Omega \rightarrow \mathbb{R}$ (non necessariamente normale) con $\mathbb{E}(X) = \mu$ e $\text{Var}(X) = \sigma^2$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione con $n \geq 30$. Supponiamo che σ^2 sia nota (es.: si sa *a priori* che $\sigma^2 = 1$).

7.2.7.1. *IC bilaterale per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché il campione X_1, \dots, X_n è numeroso ($n \geq 30$) si può applicare il Teorema del Limite Centrale per concludere che $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ è approssimata da $Z \sim \mathcal{N}(0, 1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &\simeq \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq Z \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &= 1 - \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) - \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha.$$

Decidiamo di equipartire α :

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}. \quad (7.10)$$

Definiamo $z_{\alpha/2}$ come il punto tale che

$$\mathbb{P}(\{Z \geq z_{\alpha/2}\}) = \frac{\alpha}{2}.$$




FIGURA 7.11. Definizione di $z_{\alpha/2}$ e di $-z_{\alpha/2}$ (per simmetria).

Scegliendo

$$\frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}} = z_{\alpha/2} \implies U_n = \bar{X}_n - \frac{\sigma}{\sqrt{n}} z_{\alpha/2},$$

$$\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} = -z_{\alpha/2} \implies V_n = \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_{\alpha/2},$$

si ottiene (7.10). In conclusione

$$\left[\bar{X}_n - \frac{\sigma}{\sqrt{n}} z_{\alpha/2}, \bar{X}_n + \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right]$$

è un intervallo di confidenza bilaterale per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.7.2. *Limite di confidenza inferiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{U_n \leq \mu\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché il campione X_1, \dots, X_n è numeroso ($n \geq 30$) si può applicare il Teorema del Limite Centrale per concludere che $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ è approssimata da $Z \sim \mathcal{N}(0, 1)$. Allora

$$\begin{aligned} \beta &= \mathbb{P}(\{U_n \leq \mu\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) \\ &\simeq \mathbb{P}\left(\left\{Z \leq \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z > \frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.11)$$

Definiamo z_α come il punto tale che

$$\mathbb{P}(\{Z \geq z_\alpha\}) = \alpha.$$




FIGURA 7.12. Definizione di z_α .

Scegliendo

$$\frac{\bar{X}_n - U_n}{\sigma/\sqrt{n}} = z_\alpha \implies U_n = \bar{X}_n - \frac{\sigma}{\sqrt{n}} z_\alpha,$$

si ottiene (7.11). In conclusione

$$\left[\bar{X}_n - \frac{\sigma}{\sqrt{n}} z_\alpha, +\infty \right)$$

è un intervallo di confidenza unilaterale destro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.7.3. *Limite di confidenza superiore per μ .* Dalla definizione di IC si ha che

$$\beta = \mathbb{P}(\{\mu \leq V_n\}).$$

Per stimare μ sfrutteremo lo stimatore media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Poiché il campione X_1, \dots, X_n è numeroso ($n \geq 30$) si può applicare il Teorema del Limite Centrale per concludere che $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$ è approssimata da $Z \sim \mathcal{N}(0, 1)$. Allora


$$\begin{aligned} \beta &= \mathbb{P}(\{\mu \leq V_n\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}\right\}\right) \\ &\simeq \mathbb{P}\left(\left\{\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} \leq Z\right\}\right) = 1 - \mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right). \end{aligned}$$

Segue che

$$\mathbb{P}\left(\left\{Z < \frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}}\right\}\right) = 1 - \beta = \alpha. \quad (7.12)$$

Definiamo z_α come il punto tale che

$$\mathbb{P}(\{Z \geq z_\alpha\}) = \alpha.$$

FIGURA 7.13. Definizione di $-z_\alpha$.

Scegliendo

$$\frac{\bar{X}_n - V_n}{\sigma/\sqrt{n}} = -z_\alpha \implies V_n = \bar{X}_n + \frac{\sigma}{\sqrt{n}}z_\alpha,$$

si ottiene (7.12). In conclusione

$$\left(-\infty, \bar{X}_n + \frac{\sigma}{\sqrt{n}}z_\alpha \right]$$

è un intervallo di confidenza unilaterale sinistro per μ con livello di confidenza $\beta = 1 - \alpha$.

7.2.8. Esercizi. Qui di seguito sono riportati alcuni esercizi per verificare la comprensione degli argomenti trattati.

ESERCIZIO 7.12. Lavori per un'azienda che produce batterie. Si sa che la deviazione standard per la durata in ore di questo tipo di batterie è di $\sigma = 10$ ore. Vuoi stimare la durata media delle batterie. Testi 40 campioni, osservando una media campionaria di 96.5 ore.

- (1) Calcola sui dati del campione un intervallo di confidenza bilaterale al 95%.
- (2) Calcola sui dati del campione un intervallo di confidenza destro al 90%.

□

ESERCIZIO 7.13. Si vuole stimare, tramite uno studio statistico, quante ore al giorno trascorrono gli/le adolescenti con lo smartphone. Ad alcuni/e adolescenti scelti casualmente è stato chiesto quante ore al giorno trascorrono con lo smartphone. I dati (in ore) sono i seguenti:

3.0 3.5 5.1 3.4 4.2 5.3 4.7 3.9 3.7 4.6 4.1 3.0 4.3 5.6 3.6 4.2
5.2 4.6 6.0 4.7 4.0 5.0 5.7 4.9 3.3 3.0 2.9 3.8 5.9 4.4 3.5 5.0

(La media calcolata sui dati è: 4.3.) Si sa che la deviazione standard per la popolazione è $\sigma = 1$.

- (1) Calcolare sui dati un intervallo di confidenza bilaterale al 99%.
- (2) Calcolare sui dati un intervallo di confidenza unilaterale destro al 95%. (Limite inferiore di confidenza.)

□

ESERCIZIO 7.14. Un campione di 40 elementi estratto da una popolazione con deviazione standard nota $\sigma = 3$ ha media campionaria 10.

- (1) Trovare un intervallo di confidenza al 99% per la media.
- (2) Trovare un limite inferiore di confidenza al 90% per la media.
- (3) Trovare un limite superiore di confidenza al 95% per la media.

□

CAPITOLO 8

Test di ipotesi

Contenuti

8.1. Introduzione e definizioni	183
8.2. Impostazione di un test di ipotesi	188
8.3. Esempi di test di ipotesi	189
8.3.1. Popolazione normale, μ incognita, σ^2 nota: test su μ	189
8.3.1.1. Test bilaterale su μ	189
8.3.1.2. Test unilaterale destro su μ	190
8.3.1.3. Test unilaterale destro su μ (variante)	192
8.3.1.4. Test unilaterale sinistro su μ	193
8.3.1.5. Test unilaterale sinistro su μ (variante)	195
8.3.2. Esercizi	196
8.3.3. Popolazione normale, μ incognita, σ^2 incognita: test su σ^2	198
8.3.3.1. Test bilaterale su σ^2	198
8.3.3.2. Test unilaterale destro su σ^2	200
8.3.3.3. Test unilaterale destro su σ^2 (variante)	201
8.3.3.4. Test unilaterale sinistro su σ^2	203
8.3.3.5. Test unilaterale sinistro su σ^2 (variante)	204
8.3.4. Esercizi	205
8.3.5. Popolazione normale, μ incognita, σ^2 incognita: test su μ	206
8.3.5.1. Test bilaterale su μ	206
8.3.5.2. Test unilaterale destro su μ	208
8.3.5.3. Test unilaterale destro su μ (variante)	209
8.3.5.4. Test unilaterale sinistro su μ	210
8.3.5.5. Test unilaterale sinistro su μ (variante)	212
8.3.6. Esercizi	213
8.3.7. Campione numeroso, μ incognita, σ^2 nota: test su μ	214
8.3.7.1. Test bilaterale su μ	214
8.3.7.2. Test unilaterale destro su μ	216
8.3.7.3. Test unilaterale destro su μ (variante)	217
8.3.7.4. Test unilaterale sinistro su μ	219
8.3.7.5. Test unilaterale sinistro su μ (variante)	220
8.3.8. Esercizi	222

8.1. Introduzione e definizioni

Si consideri una popolazione distribuita con la legge di una variabile aleatoria $X: \Omega \rightarrow \mathbb{R}$. Supponiamo che X dipenda da parametri $\theta \in \Theta$. Sia $h: \Theta \rightarrow \mathbb{R}$ una funzione. Il

parametro $h(\theta)$ è quello su cui si vuole testare un'ipotesi.

Un test di ipotesi è impostato nel seguente modo. Prima di effettuare misurazioni su un campione di dati, abbiamo delle assunzioni sul parametro $h(\theta)$. Queste assunzioni possono ad esempio dipendere da esperimenti eseguiti in passato sulla popolazione X . Riassumiamo queste assunzioni in quella che viene nominata *ipotesi nulla*:

$$H_0 : h(\theta) \in E_0,$$

dove $E_0 \subset h(\Theta)$ descrive un insieme di parametri. L'ipotesi nulla si interpreta nel seguente modo:

“Fino a prova contraria, si deve assumere per vera $H_0 : h(\theta) \in E_0$ ”.

ESEMPIO 8.1. Sia $X \sim \mathcal{N}(\mu, \sigma^2)$ la variabile aleatoria che descrive una popolazione. Alcuni esempi di ipotesi nulle sono

- $H_0 : \mu = \mu_0$ (corrisponde a $E_0 = \{\mu_0\}$);
- $H_0 : \mu \geq \mu_0$ (corrisponde a $E_0 = [\mu_0, +\infty)$);
- $H_0 : \mu \leq \mu_0$ (corrisponde a $E_0 = (-\infty, \mu_0]$);
- $H_0 : \sigma^2 = \sigma_0^2$ (corrisponde a $E_0 = \{\sigma_0\}$);
- $H_0 : \sigma^2 \geq \sigma_0^2$ (corrisponde a $E_0 = [\sigma_0^2, +\infty)$);
- $H_0 : \sigma^2 \leq \sigma_0^2$ (corrisponde a $E_0 = (0, \sigma_0^2]$).

□

Il test di ipotesi si utilizza per valutare in modo quantitativo se ci sono prove statisticamente *significative* che permettono di confutare l'ipotesi nulla a favore dell'accettazione di un'*ipotesi alternativa*

$$H_1 : h(\theta) \in E_1,$$

dove $E_1 \subset h(\Theta)$ è un altro insieme di parametri.

ESEMPIO 8.2. Sia $X \sim \mathcal{N}(\mu, \sigma^2)$ la variabile aleatoria che descrive una popolazione. Alcuni esempi di ipotesi nulle confrontate con ipotesi alternative sono

- $H_0 : \mu = \mu_0, H_1 : \mu \neq \mu_0$;
- $H_0 : \mu = \mu_0, H_1 : \mu < \mu_0$;
- $H_0 : \mu = \mu_0, H_1 : \mu > \mu_0$;
- $H_0 : \mu \geq \mu_0, H_1 : \mu < \mu_0$;
- $H_0 : \mu \leq \mu_0, H_1 : \mu > \mu_0$;
- $H_0 : \sigma^2 = \sigma_0^2, H_1 : \sigma^2 \neq \sigma_0^2$;
- $H_0 : \sigma^2 = \sigma_0^2, H_1 : \sigma^2 < \sigma_0^2$;
- $H_0 : \sigma^2 = \sigma_0^2, H_1 : \sigma^2 > \sigma_0^2$;
- $H_0 : \sigma^2 \geq \sigma_0^2, H_1 : \sigma^2 < \sigma_0^2$;
- $H_0 : \sigma^2 \leq \sigma_0^2, H_1 : \sigma^2 > \sigma_0^2$.

□

Per valutare se ci sono prove statisticamente significative che permettono di confutare l'ipotesi nulla, si analizza un campione casuale X_1, \dots, X_n estratto dalla popolazione

(ovvero: X_1, \dots, X_n sono indipendenti e identicamente distribuite a X). Si osservano i dati del campione, ovvero una realizzazione del campione casuale $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$. Se i dati (x_1, \dots, x_n) sono sufficientemente significativi da confutare l'ipotesi nulla H_0 , allora H_0 viene rifiutata e si accetta l'ipotesi alternativa H_1 .



FIGURA 8.1. A sinistra: Jerzy Neyman (1894–1981).^a A destra: Egon Pearson (1895–1980).^b Hanno sviluppato la teoria matematica dei test di ipotesi.

^aFonte dell'immagine: https://commons.wikimedia.org/wiki/File:Jerzy_Neyman2.jpg.

^bFonte dell'immagine: https://en.wikipedia.org/wiki/File:Egon_Pearson.jpg.

ESEMPIO 8.3. Fino allo scorso anno, gli/le adolescenti trascorrevano in media 3 ore al giorno con lo smartphone. Viene effettuato un nuovo sondaggio, chiedendo a un campione di 15 adolescenti il numero di ore trascorse al giorno con lo smartphone. I dati sono i seguenti:

3.4 2.8 4.9 3.5 4.8 4.1 4.0 3.2 5.5 3.2 4.4 5.3 5.3 4.7 4.3.

La media calcolata sui dati del campione è $\bar{x}_n \simeq 4.23$. I dati sono abbastanza significativi da stabilire che la media della popolazione è più grande di 3? Oppure il fatto che la media calcolata sui dati del campione sia strettamente maggiore di 3 è solo dovuto alla particolare realizzazione dei dati misurati?

Questa domanda si traduce in un test di ipotesi. Il campione casuale X_1, \dots, X_n con $n = 15$ è costituito da variabili aleatorie indipendenti e identicamente distribuite con parametro $\mathbb{E}(X_i) = \mu$. L'ipotesi nulla e l'ipotesi alternativa sono:

$$H_0 : \mu = 3, \quad H_1 : \mu > 3.$$

Si vuole stabilire se i dati (x_1, \dots, x_n) permettono di confutare H_0 a favore di H_1 . \square

Il rifiuto dell'ipotesi nulla a favore dell'ipotesi alternativa è una decisione basata sui dati osservati (x_1, \dots, x_n) . Considereremo una *regione critica* o *regione di rifiuto* data da un sottoinsieme del range del campione casuale X_1, \dots, X_n

$$R_c \subset R(X_1, \dots, X_n).$$

Data la regione critica, si decide seguendo questo schema:

- Se i dati sono nella regione critica, $(x_1, \dots, x_n) \in R_c$, i dati sono valutati come sufficientemente significativi da confutare H_0 , e quindi H_0 viene rifiutata a favore dell'ipotesi alternativa H_1 ;
- Se i dati sono fuori dalla regione critica $(x_1, \dots, x_n) \notin R_c$, i dati non sono sufficientemente significativi da confutare H_0 , quindi l'ipotesi nulla H_0 non può essere rifiutata.

ESEMPIO 8.4. Nell'Esempio 8.3, i dati sono sufficientemente significativi per stabilire che la media della popolazione è aumentata se la media calcolata sui dati del campione è ben più grande di 3. Questo vuol dire che la regione critica è

$$R_c = \{(x_1, \dots, x_n) : \bar{x}_n > 3 + \delta\},$$

dove lo scarto $\delta > 0$ verrà scelto opportunamente. □

Per definire la regione critica in modo quantitativo si introduce la seguente nozione di errore.

DEFINIZIONE 8.5. Un *errore del I tipo* è l'errore commesso nel rifiutare l'ipotesi nulla quando questa è vera. Un *errore del II tipo* è l'errore commesso nel non rifiutare l'ipotesi nulla quando questa è falsa. □

	H_0 vera	H_0 falsa
H_0 non rifiutata	✓	errore del II tipo
H_0 rifiutata	errore del I tipo	✓

TABELLA 1. Schema riassuntivo per gli errori nei test di ipotesi.

Per effettuare un test di ipotesi ci interessano gli *errori del I tipo*.




FIGURA 8.2. *xkcd* 2303. ERROR TYPES. Credits: <https://xkcd.com/2303/>

DEFINIZIONE 8.6. Sia X la variabile aleatorie che descrive una popolazione. Supponiamo che X dipenda da un parametro $\theta \in \Theta$. Sia $h : \Theta \rightarrow \mathbb{R}$ una funzione. Consideriamo un test di ipotesi su $h(\theta)$ della forma

$$H_0 : h(\theta) \in E_0, \quad H_1 : h(\theta) \in E_1.$$

Sia X_1, \dots, X_n un campione casuale estratto dalla popolazione. Sia $\alpha \in (0, 1)$. Sia $R_c = R_c(\alpha) \subset R(X_1, \dots, X_n)$ la regione di rifiuto per il test di ipotesi. Si dice che il test di ipotesi ha *livello di significatività* α se α è la probabilità di commettere un errore del I tipo, ovvero, assumendo che H_0 sia vera,

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c(\alpha)\}).$$

□

Valori tipici di α sono: 10%, 5%, 2.5%, 1%, 0.5%. Valori di α molto piccoli corrispondono a una bassa probabilità di commettere un errore nel rifiutare l'ipotesi nulla quando questa è vera. Dati che confutano l'ipotesi nulla con livelli di significatività molto piccoli sono dati molto significativi.

Nella seguente definizione introduciamo il più piccolo livello di significatività per cui i dati osservati permettono di rifiutare l'ipotesi nulla.

DEFINIZIONE 8.7. Sia X la variabile aleatorie che descrive una popolazione. Supponiamo che X dipenda da un parametro $\theta \in \Theta$. Sia $h : \Theta \rightarrow \mathbb{R}$ una funzione. Consideriamo un test di ipotesi su $h(\theta)$ della forma

$$H_0 : h(\theta) \in E_0, \quad H_1 : h(\theta) \in E_1.$$

Sia X_1, \dots, X_n un campione casuale estratto dalla popolazione. Sia $R_c \subset R(X_1, \dots, X_n)$ la regione di rifiuto per il test di ipotesi. Siano $(x_1, \dots, x_n) \in R(X_1, \dots, X_n)$ i dati osservati del campione. Il *p-value dei dati* è

$$p\text{-value} = \inf\{\alpha : (x_1, \dots, x_n) \in R_c(\alpha)\}.$$

□

È utile calcolare il *p-value dei dati* perché: se $\alpha \geq p\text{-value}$, allora l'ipotesi nulla H_0 è rifiutata, se $\alpha < p\text{-value}$, l'ipotesi nulla H_0 non è rifiutata.

<u>P-VALUE</u>	<u>INTERPRETATION</u>
0.001	HIGHLY SIGNIFICANT
0.01	
0.02	
0.03	
0.04	SIGNIFICANT
0.049	OH CRAP. REDO CALCULATIONS.
0.050	
0.051	ON THE EDGE OF SIGNIFICANCE
0.06	HIGHLY SUGGESTIVE, SIGNIFICANT AT THE P<0.10 LEVEL
0.07	
0.08	
0.09	HEY, LOOK AT THIS INTERESTING SUBGROUP ANALYSIS
0.099	
≥ 0.1	

FIGURA 8.3. *xkcd* 1478. P-VALUES. Credits: <https://xkcd.com/1478/>

8.2. Impostazione di un test di ipotesi

Quando si imposta un test di ipotesi, occorre seguire i seguenti passi:

- (1) Identificare l'ipotesi nulla H_0 e l'ipotesi alternativa H_1 .
- (2) Stabilire la forma della regione critica sulla base dell'ipotesi alternativa.
- (3) Assumere H_0 vera.
- (4) Legare la regione critica $R_c(\alpha)$ al livello di significatività α .
- (5) Osservare i dati x_1, \dots, x_n . Se $(x_1, \dots, x_n) \in R_c(\alpha)$, allora H_0 viene rifiutata. Se $(x_1, \dots, x_n) \notin R_c(\alpha)$, allora H_0 non viene rifiutata.

Se possibile, si può seguire il seguente approccio alternativo:

- (1) Identificare l'ipotesi nulla H_0 e l'ipotesi alternativa H_1 .
- (2) Stabilire la forma della regione critica sulla base dell'ipotesi alternativa.
- (3) Assumere H_0 vera.
- (4) Legare la regione critica $R_c(\alpha)$ al livello di significatività α .
- (5) Osservare i dati x_1, \dots, x_n e calcolare il *p-value* sui dati.

- (6) Se $\alpha \geq p\text{-value}$, allora H_0 viene rifiutata. Se $\alpha < p\text{-value}$, allora H_0 non viene rifiutata.

8.3. Esempi di test di ipotesi

8.3.1. Popolazione normale, μ incognita, σ^2 nota: test su μ . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione. Supponiamo che σ^2 sia nota (es.: si sa *a priori* che $\sigma^2 = 1$).

8.3.1.1. *Test bilaterale su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu \neq \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu \neq \mu_0$, i dati saranno significativi se la media è sufficientemente distante da μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Dalla definizione di livello di significatività e utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{|\bar{X}_n - \mu_0| > \delta\}) = \mathbb{P}\left(\left\{\frac{|\bar{X}_n - \mu_0|}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $Z = \frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Quindi, per la simmetria della gaussiana


$$\begin{aligned} \alpha &= \mathbb{P}\left(\left\{|Z| > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \\ &= 2\mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right), \end{aligned} \tag{8.1}$$

da cui

$$\mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}.$$

Introduciamo il valore $z_{\alpha/2}$ tale che

$$\mathbb{P}(\{Z > z_{\alpha/2}\}) = \frac{\alpha}{2}.$$

FIGURA 8.4. Code della legge normale con probabilità $\frac{\alpha}{2}$.

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_{\alpha/2} \implies \delta = \frac{\sigma}{\sqrt{n}} z_{\alpha/2},$$

otteniamo (8.1).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right\},$$

e decidiamo come segue:

- Se $|\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $|\bar{x}_n - \mu_0| \leq \frac{\sigma}{\sqrt{n}} z_{\alpha/2}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : |\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right\} = \inf \left\{ \alpha : \frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} > z_{\alpha/2} \right\} \\ &= \inf \left\{ \alpha : \Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) > \Phi(z_{\alpha/2}) \right\} = \inf \left\{ \alpha : \Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) > 1 - \frac{\alpha}{2} \right\} \\ &= \inf \left\{ \alpha : \alpha > 2 - 2\Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) \right\} = 2 - 2\Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right). \end{aligned}$$

8.3.1.2. *Test unilaterale destro su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se sufficientemente più grandi di μ_0 . La regione critica è allora della forma

$$R_c = \{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta \},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Dalla definizione di livello di significatività e utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $Z = \frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right). \quad (8.2)$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.5. Coda destra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (8.2).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.8. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} > z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) > \Phi(z_\alpha) \right\} = \inf \left\{ \alpha : \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) > 1 - \alpha \right\} \\ &= \inf \left\{ \alpha : \alpha > 1 - \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) \right\} = 1 - \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right). \end{aligned}$$

8.3.1.3. *Test unilaterale destro su μ (variante)*. Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \leq \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se la media è sufficientemente più grande di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \leq \mu_0$.

OSSERVAZIONE 8.9. Attenzione: se $\mu \leq \mu_0$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ come prima. Il valore della media della popolazione è μ , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\mu \leq \mu_0$

$$\bar{X}_n > \mu_0 + \delta \implies \bar{X}_n > \mu + \delta.$$


Utilizziamo questo per il calcolo della regione critica. □

Utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) \leq \mathbb{P}(\{\bar{X}_n > \mu + \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right), \end{aligned}$$

dove $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti. Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$

FIGURA 8.6. Coda destra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.10. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} > z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > \Phi(z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > 1 - \alpha \right\} \\ &= \inf \left\{ \alpha : \alpha > 1 - \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) \right\} = 1 - \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.1.4. *Test unilaterale sinistro su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficiente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Dalla definizione di livello di significatività e utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $Z = \frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right). \quad (8.3)$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.7. Coda sinistra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (8.3).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.11. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} < -z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \Phi(-z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \alpha \right\} \\ &= \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.1.5. *Test unilaterale sinistro su μ (variante)*. Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \geq \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficientemente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \geq \mu_0$.

OSSERVAZIONE 8.12. Attenzione: se $\mu \geq \mu_0$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ come prima. Il valore della media della popolazione è μ , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\mu \geq \mu_0$

$$\bar{X}_n < \mu_0 - \delta \implies \bar{X}_n < \mu - \delta.$$


Utilizziamo questo per il calcolo della regione critica. \square

Utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) \leq \mathbb{P}(\{\bar{X}_n < \mu - \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right), \end{aligned}$$

dove $Z = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti. Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$

FIGURA 8.8. Coda sinistra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.13. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} < -z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \Phi(-z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > \alpha \right\} \\ &= \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.2. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 8.14. Viene analizzata la resa di un processo chimico. Gli ultimi cinque giorni di funzionamento dell'impianto hanno prodotto le seguenti rese (esprese in percentuale): 91.6, 88.75, 90.8, 89.95 e 91.3. Dall'esperienza precedente è noto che la resa ha distribuzione normale con deviazione standard $\sigma = 3$.

- (1) C'è un'evidenza al 5% di significatività che la resa media reale non sia 90?
- (2) Qual è il p -value del test?

□

ESERCIZIO 8.15. (I dati sono inventati.) Uno studio statistico ha riferito che precedentemente gli/le adolescenti trascorrevano in media 3 ore al giorno con lo smartphone. Si vuole mostrare con un'evidenza statistica che la media è diventata più alta. Ad alcuni/e adolescenti scelti casualmente è stato chiesto quante ore al giorno trascorrono con lo smartphone. I dati (in ore) sono i seguenti:

3.4 2.8 4.9 3.5 4.8 4.1 4.0 3.2 5.5 3.2 4.4 5.3 5.3 4.7 4.3.

Si sa che la popolazione ha una distribuzione normale con deviazione standard $\sigma = 0.8$.

- (1) I dati sono significativi al 10% per stabilire che la media è davvero più alta?

□

ESERCIZIO 8.16. Un'azienda produce alberi a gomiti per motori di autoveicoli. L'usura dell'albero motore dopo 100.000 miglia (calcolata in 0.001 mm) è interessante perché è probabile che abbia un impatto sulle richieste di garanzia. Viene testato un campione casuale di 15 alberi la media campionaria risulta essere 7.06 (per 0.001 mm). È noto che l'usura è normalmente distribuita con deviazione standard $\sigma = 0.23$. C'è un'evidenza con il 5% di significatività che la media reale di usura sia diversa da 3? □

ESERCIZIO 8.17. Dei provini cilindrici di calcestruzzo mostrano le seguenti resistenze a compressione (in MPa):

17 21 21 26 24 19 14 19 23 27 31 31 26 26 22 27

Sapendo che il campione è estratto da una popolazione normale con media incognita μ e varianza nota $\sigma^2 = 4$, con che livelli di significatività si può accettare l'ipotesi $\mu = 25$? □

ESERCIZIO 8.18. È noto che la durata in ore di una batteria è distribuita in modo normale, con deviazione standard $\sigma = 1.25$ ore. La durata media calcolata su un campione casuale di 10 batterie è risultata essere 40.5 ore.

- (1) C'è un'evidenza a sostegno dell'affermazione che la durata media della batteria reale superi le 40 ore? Usare una significatività del 10%.
- (2) Qual è il p -value del test?

□

ESERCIZIO 8.19. La temperatura media dell'acqua a valle del tubo di scarico della torre di raffreddamento di una centrale elettrica non deve essere superiore a $100^\circ F$. L'esperienza passata ha indicato che la temperatura ha una distribuzione normale con deviazione standard $1.8^\circ F$. La temperatura dell'acqua viene misurata in nove giorni scelti casualmente

fornendo le seguenti misurazioni in gradi Celsius:

37.65 36.51 37.79 37.60 38.38 37.65 38.79 39.83 37.07.

(Ricordiamo che $(y^\circ F - 32)\frac{5}{9} = x^\circ C$.)

- (1) La temperatura dell'acqua può essere giudicata inaccettabile con significatività 0.05?
- (2) Qual è il p -value per questo test?

□

ESERCIZIO 8.20. Nella progettazione del propellente composito per un razzo si analizza un campione di ampiezza $n = 9$ di leganti polimerici. Il punto di fusione medio calcolato sul campione di leganti è $67.5^\circ C$ (gradi Celsius). Si sa che il punto di fusione ha distribuzione normale con deviazione standard $1.8^\circ F$ (Attenzione: espressa in gradi Fahrenheit!)

- (1) Ricordando che $x^\circ F$ corrispondono a $(x - 32)\frac{5}{9}^\circ C$, qual è la deviazione standard della distribuzione normale espressa in gradi Celsius $^\circ C$? (Suggerimento: utilizzare le proprietà della varianza di una variabile aleatoria X per determinare come viene modificata in seguito a trasformazioni del tipo $X + b$ e aX con $a, b \in \mathbb{R}$)
- (2) Testare l'ipotesi $H_0 : \mu = 68^\circ C$ contro $H_1 : \mu \neq 68^\circ C$ con un livello di significatività dell'1%.
- (3) Quanto dovrebbe essere grande l'ampiezza del campione n per rifiutare l'ipotesi H_0 con significatività del 5%? (Si assuma che la media calcolata sul campione sia sempre 67.5)

□

8.3.3. Popolazione normale, μ incognita, σ^2 incognita: test su σ^2 . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione.

8.3.3.1. *Test bilaterale su σ^2 .* Sia σ_0^2 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \sigma^2 = \sigma_0^2, \quad H_1 : \sigma^2 \neq \sigma_0^2,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \sigma^2 \neq \sigma_0^2$, i dati saranno significativi se la varianza è sufficientemente distante da σ_0^2 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \delta_1 \sigma_0^2 \text{ oppure } s_n^2 > \delta_2 \sigma_0^2\},$$

dove $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ e $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ sono la varianza e la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\sigma^2 = \sigma_0^2$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma_0^2)$. Dalla definizione di livello di significatività e utilizzando la varianza campionaria $S_n^2 =$

$$\begin{aligned} & \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2, \\ \alpha &= \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{S_n^2 < \delta_1 \sigma_0^2\} \cup \{S_n^2 > \delta_2 \sigma_0^2\}) \\ &= \mathbb{P}(\{S_n^2 < \delta_1 \sigma^2\} \cup \{S_n^2 > \delta_2 \sigma^2\}) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} < (n-1)\delta_1\right\}\right) + \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} > (n-1)\delta_2\right\}\right). \end{aligned}$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti, si ha che $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Quindi

$$\alpha = \mathbb{P}(\{Q_{n-1} < (n-1)\delta_1\}) + \mathbb{P}(\{Q_{n-1} > (n-1)\delta_2\}).$$

Decidiamo di equipartire α :

$$\mathbb{P}(\{Q_{n-1} < (n-1)\delta_1\}) = \mathbb{P}(\{Q_{n-1} > (n-1)\delta_2\}) = \frac{\alpha}{2}. \quad (8.4)$$

Introduciamo i valori $\chi_{n-1, \alpha/2}^2$ e $\chi_{n-1, 1-\alpha/2}^2$ tali che

$$\mathbb{P}(\{Q_{n-1} > \chi_{n-1, \alpha/2}^2\}) = \frac{\alpha}{2}, \quad \mathbb{P}(\{Q_{n-1} > \chi_{n-1, 1-\alpha/2}^2\}) = 1 - \frac{\alpha}{2}.$$




FIGURA 8.9. Code della legge chi-quadro con probabilità $\frac{\alpha}{2}$.

Allora, scegliendo

$$\begin{aligned} (n-1)\delta_1 &= \chi_{n-1, 1-\alpha/2}^2 \implies \delta_1 = \frac{\chi_{n-1, 1-\alpha/2}^2}{n-1}, \\ (n-1)\delta_2 &= \chi_{n-1, \alpha/2}^2 \implies \delta_2 = \frac{\chi_{n-1, \alpha/2}^2}{n-1}, \end{aligned}$$

otteniamo (8.4).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \frac{\chi_{n-1, 1-\alpha/2}^2}{n-1} \sigma_0^2 \text{ oppure } s_n^2 > \frac{\chi_{n-1, \alpha/2}^2}{n-1} \sigma_0^2 \right\},$$

e decidiamo come segue:

- Se $s_n^2 < \frac{\chi_{n-1, 1-\alpha/2}^2}{n-1} \sigma_0^2$ oppure $s_n^2 > \frac{\chi_{n-1, \alpha/2}^2}{n-1} \sigma_0^2$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).

- Se $\frac{\chi_{n-1,1-\alpha/2}^2}{n-1}\sigma_0^2 \leq s_n^2 \leq \frac{\chi_{n-1,\alpha/2}^2}{n-1}\sigma_0^2$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione chi-quadro tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : s_n^2 < \frac{\chi_{n-1,1-\alpha/2}^2}{n-1}\sigma_0^2 \text{ oppure } s_n^2 > \frac{\chi_{n-1,\alpha/2}^2}{n-1}\sigma_0^2 \right\}.$$

8.3.3.2. *Test unilaterale destro su σ^2* . Sia σ_0^2 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \sigma^2 = \sigma_0^2, \quad H_1 : \sigma^2 > \sigma_0^2,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \sigma^2 > \sigma_0^2$, i dati saranno significativi se la varianza è sufficientemente più grande di σ_0^2 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 > \delta\sigma_0^2\},$$

dove $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ e $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ sono la varianza e la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\sigma^2 = \sigma_0^2$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma_0^2)$. Dalla definizione di livello di significatività e utilizzando la varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$,

$$\begin{aligned} \alpha &= \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{S_n^2 > \delta\sigma_0^2\}) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} > (n-1)\delta\right\}\right). \end{aligned}$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti, si ha che $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Quindi

$$\alpha = \mathbb{P}(\{Q_{n-1} > (n-1)\delta\}). \quad (8.5)$$

Introduciamo il valore $\chi_{n-1,\alpha}^2$ tale che

$$\mathbb{P}(\{Q_{n-1} > \chi_{n-1,\alpha}^2\}) = \alpha.$$




FIGURA 8.10. Coda destra della legge chi-quadro con probabilità α .

Allora, scegliendo

$$(n-1)\delta = \chi_{n-1,\alpha}^2 \implies \delta = \frac{\chi_{n-1,\alpha}^2}{n-1},$$

otteniamo (8.5).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 > \frac{\chi_{n-1,\alpha}^2}{n-1} \sigma_0^2 \right\},$$

e decidiamo come segue:

- Se $s_n^2 > \frac{\chi_{n-1,\alpha}^2}{n-1} \sigma_0^2$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $s_n^2 \leq \frac{\chi_{n-1,\alpha}^2}{n-1} \sigma_0^2$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.21. Questo tipo di test ha senso solo quando $s_n^2 > \sigma_0^2$. Se $s_n^2 \leq \sigma_0^2$, ovviamente i dati non saranno significativi per stabilire che $\sigma^2 > \sigma_0^2$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione chi-quadro tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : s_n^2 > \frac{\chi_{n-1,\alpha}^2}{n-1} \sigma_0^2 \right\}.$$

8.3.3.3. *Test unilaterale destro su σ^2 (variante)*. Sia σ_0^2 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \sigma^2 \leq \sigma_0^2, \quad H_1 : \sigma^2 > \sigma_0^2,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \sigma^2 > \sigma_0^2$, i dati saranno significativi se la varianza è sufficientemente più grande di σ_0^2 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 > \delta \sigma_0^2\},$$

dove $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ e $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ sono la varianza e la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

OSSERVAZIONE 8.22. Attenzione: se $\sigma^2 \leq \sigma_0^2$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma_0^2)$ come prima. Il valore della varianza della popolazione è σ^2 , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\sigma^2 \leq \sigma_0^2$

$$S_n^2 > \delta \sigma_0^2 \implies S_n^2 > \delta \sigma^2.$$

Utilizziamo questo per il calcolo della regione critica. \square

Assumiamo l'ipotesi nulla H_0 vera, cioè $\sigma^2 \leq \sigma_0^2$. Dalla definizione di livello di significatività e utilizzando la varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{S_n^2 > \delta \sigma_0^2\}) \leq \mathbb{P}(\{S_n^2 > \delta \sigma^2\}) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} > (n-1)\delta\right\}\right). \end{aligned}$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti, si ha che $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Introduciamo il valore $\chi_{n-1, \alpha}^2$ tale che

$$\mathbb{P}(\{Q_{n-1} > \chi_{n-1, \alpha}^2\}) = \alpha.$$




FIGURA 8.11. Coda destra della legge chi-quadro con probabilità α .

Allora, scegliendo

$$(n-1)\delta = \chi_{n-1, \alpha}^2 \implies \delta = \frac{\chi_{n-1, \alpha}^2}{n-1},$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 > \frac{\chi_{n-1, \alpha}^2}{n-1} \sigma_0^2 \right\},$$

e decidiamo come segue:

- Se $s_n^2 > \frac{\chi_{n-1, \alpha}^2}{n-1} \sigma_0^2$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $s_n^2 \leq \frac{\chi_{n-1, \alpha}^2}{n-1} \sigma_0^2$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.23. Questo tipo di test ha senso solo quando $s_n^2 > \sigma_0^2$. Se $s_n^2 \leq \sigma_0^2$, ovviamente i dati non saranno significativi per stabilire che $\sigma^2 > \sigma_0^2$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione chi-quadro tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : s_n^2 > \frac{\chi_{n-1, \alpha}^2}{n-1} \sigma_0^2 \right\}.$$

8.3.3.4. *Test unilaterale sinistro su σ^2* . Sia σ_0^2 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \sigma^2 = \sigma_0^2, \quad H_1 : \sigma^2 < \sigma_0^2,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \sigma^2 < \sigma_0^2$, i dati saranno significativi se la varianza è sufficientemente più piccola di σ_0^2 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \delta \sigma_0^2\},$$

dove $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ e $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ sono la varianza e la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\sigma^2 = \sigma_0^2$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma_0^2)$. Dalla definizione di livello di significatività e utilizzando la varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$,

$$\begin{aligned} \alpha &= \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{S_n^2 < \delta \sigma_0^2\}) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} < (n-1)\delta\right\}\right). \end{aligned}$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti, si ha che $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Quindi

$$\alpha = \mathbb{P}(\{Q_{n-1} < (n-1)\delta\}) \implies \mathbb{P}(\{Q_{n-1} > (n-1)\delta\}) = 1 - \alpha. \quad (8.6)$$

Introduciamo il valore $\chi_{n-1, 1-\alpha}^2$ tale che

$$\mathbb{P}(\{Q_{n-1} > \chi_{n-1, 1-\alpha}^2\}) = 1 - \alpha.$$




FIGURA 8.12. Coda sinistra della legge chi-quadro con probabilità α .

Allora, scegliendo

$$(n-1)\delta = \chi_{n-1, 1-\alpha}^2 \implies \delta = \frac{\chi_{n-1, 1-\alpha}^2}{n-1},$$

otteniamo (8.6).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \frac{\chi_{n-1, 1-\alpha}^2}{n-1} \sigma_0^2 \right\},$$

e decidiamo come segue:

- Se $s_n^2 < \frac{\chi_{n-1,1-\alpha}^2}{n-1}\sigma_0^2$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $s_n^2 \leq \frac{\chi_{n-1,1-\alpha}^2}{n-1}\sigma_0^2$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.24. Questo tipo di test ha senso solo quando $s_n^2 < \sigma_0^2$. Se $s_n^2 \geq \sigma_0^2$, ovviamente i dati non saranno significativi per stabilire che $\sigma^2 < \sigma_0^2$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione chi-quadro tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : s_n^2 < \frac{\chi_{n-1,1-\alpha}^2}{n-1}\sigma_0^2 \right\}.$$

8.3.3.5. *Test unilaterale sinistro su σ^2 (variante)*. Sia σ_0^2 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \sigma^2 \geq \sigma_0^2, \quad H_1 : \sigma^2 < \sigma_0^2,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \sigma^2 < \sigma_0^2$, i dati saranno significativi se la varianza è sufficientemente più piccola di σ_0^2 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \delta\sigma_0^2\},$$

dove $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ e $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ sono la varianza e la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

OSSERVAZIONE 8.25. Attenzione: se $\sigma^2 \geq \sigma_0^2$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma_0^2)$ come prima. Il valore della varianza della popolazione è σ^2 , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\sigma^2 \geq \sigma_0^2$

$$S_n^2 < \delta\sigma_0^2 \implies S_n^2 < \delta\sigma^2.$$


Utilizziamo questo per il calcolo della regione critica. \square

Assumiamo l'ipotesi nulla H_0 vera, cioè $\sigma^2 \geq \sigma_0^2$. Dalla definizione di livello di significatività e utilizzando la varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{S_n^2 < \delta\sigma_0^2\}) \leq \mathbb{P}(\{S_n^2 < \delta\sigma^2\}) \\ &= \mathbb{P}\left(\left\{\frac{(n-1)S_n^2}{\sigma^2} < (n-1)\delta\right\}\right). \end{aligned}$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti, si ha che $Q_{n-1} = \frac{(n-1)S_n^2}{\sigma^2} \sim \chi^2(n-1)$. Introduciamo il valore $\chi_{n-1,\alpha}^2$ tale che

$$\mathbb{P}(\{Q_{n-1} > \chi_{n-1,1-\alpha}^2\}) = 1 - \alpha.$$

FIGURA 8.13. Coda sinistra della legge chi-quadro con probabilità α .

Allora, scegliendo

$$(n-1)\delta = \chi_{n-1, 1-\alpha}^2 \implies \delta = \frac{\chi_{n-1, 1-\alpha}^2}{n-1},$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : s_n^2 < \frac{\chi_{n-1, 1-\alpha}^2}{n-1} \sigma_0^2 \right\},$$

e decidiamo come segue:

- Se $s_n^2 < \frac{\chi_{n-1, 1-\alpha}^2}{n-1} \sigma_0^2$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $s_n^2 \geq \frac{\chi_{n-1, 1-\alpha}^2}{n-1} \sigma_0^2$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.26. Questo tipo di test ha senso solo quando $s_n^2 < \sigma_0^2$. Se $s_n^2 \geq \sigma_0^2$, ovviamente i dati non saranno significativi per stabilire che $\sigma^2 < \sigma_0^2$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione chi-quadro tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : s_n^2 < \frac{\chi_{n-1, 1-\alpha}^2}{n-1} \sigma_0^2 \right\}.$$

8.3.4. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 8.27. Un rivetto deve essere inserito in un foro. Viene selezionato un campione casuale di 15 parti e viene misurato il diametro del foro. La deviazione standard del campione del diametro del foro misura 0.012 millimetri e il diametro del foro ha distribuzione normale. Esistono prove evidenti per indicare che la deviazione standard del diametro del foro supera 0.01 millimetri? Usa significatività 1%. \square

ESERCIZIO 8.28. La percentuale di titanio in una lega utilizzata nelle fusioni aerospaziali è misurata in 21 parti selezionate casualmente. Si sa che è distribuita con legge normale. La deviazione standard calcolata sul campione è 0.37. C'è un'evidenza con significatività del 5% a sostegno del fatto che la deviazione standard sia diversa da 0.25? \square

ESERCIZIO 8.29. Recentemente è stata installata una macchina che controlla automaticamente la lunghezza dei nastri in una linea di produzione. Questa macchina sarà considerata efficace se la deviazione standard σ della quantità di nastro su un nastro è inferiore a 0.15 cm. Se un campione di 20 nastri produce una varianza del campione di 0.0250 cm^2 , siamo giustificati nel concludere che la macchina è inefficace? Assumere che il campione abbia distribuzione normale e utilizzare significatività 1%. \square

ESERCIZIO 8.30. Una riempitrice automatica viene utilizzata per riempire dosatori da 100 ml con gel igienizzante. Viene misurata la differenza tra il volume di riferimento 100 ml e il volume di riempimento effettivo in un campione casuale di dosatori:

4.84 -6.21 -2.59 -5.9 0.15 0.25 3.99 4.85 2.57 2.06 -5.44 0.31 -3.39

(ad esempio, il dato 4.84 indica che il dosatore è stato riempito con 104.84 ml di gel, il dato -6.21 indica che il dosatore è stato riempito con 93.79 ml di gel). Se la deviazione standard del volume di riempimento è superiore a 3 ml, la macchina riempitrice deve essere tarata nuovamente. I dati sono significativi all'1% per concludere che si deve tarare la macchina riempitrice? E al 5%? Si assuma che la popolazione sia distribuita con legge normale. \square

8.3.5. Popolazione normale, μ incognita, σ^2 incognita: test su μ . Consideriamo una popolazione $X \sim \mathcal{N}(\mu, \sigma^2)$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione.

8.3.5.1. *Test bilaterale su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu \neq \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu \neq \mu_0$, i dati saranno significativi se la media è sufficientemente distante da μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Non è nota σ^2 , quindi verrà stimata dalla varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$, dove $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ è la media campionaria. Dalla definizione di livello di significatività:

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{|\bar{X}_n - \mu_0| > \delta\}) = \mathbb{P}\left(\left\{\frac{|\bar{X}_n - \mu_0|}{S_n/\sqrt{n}} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $T_{n-1} = \frac{\bar{X}_n - \mu_0}{S_n/\sqrt{n}} \sim t(n-1)$. Quindi, per la simmetria della t-Student

$$\begin{aligned} \alpha &= \mathbb{P}\left(\left\{|T_{n-1}| > \frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} < -\frac{\delta}{S_n/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right) \\ &= 2\mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right), \end{aligned} \quad (8.7)$$

da cui

$$\mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}.$$

Introduciamo il valore $t_{n-1, \alpha/2}$ tale che

$$\mathbb{P}\left(\left\{T_{n-1} > t_{n-1, \alpha/2}\right\}\right) = \frac{\alpha}{2}.$$




FIGURA 8.14. Code della legge t-Student con probabilità $\frac{\alpha}{2}$.

Allora, scegliendo

$$\frac{\delta}{S_n/\sqrt{n}} = t_{n-1, \alpha/2} \implies \delta = \frac{S_n}{\sqrt{n}} t_{n-1, \alpha/2},$$

otteniamo (8.7).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \frac{S_n}{\sqrt{n}} t_{n-1, \alpha/2} \right\},$$

e decidiamo come segue:

- Se $|\bar{x}_n - \mu_0| > \frac{S_n}{\sqrt{n}} t_{n-1, \alpha/2}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $|\bar{x}_n - \mu_0| \leq \frac{S_n}{\sqrt{n}} t_{n-1, \alpha/2}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione t-Student tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : |\bar{x}_n - \mu_0| > \frac{S_n}{\sqrt{n}} t_{n-1, \alpha/2} \right\}.$$

8.3.5.2. *Test unilaterale destro su μ* . Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se sufficientemente più grandi di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Non è nota σ^2 , quindi verrà stimata dalla varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$, dove $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ è la media campionaria. Dalla definizione di livello di significatività:

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{S_n/\sqrt{n}} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $T_{n-1} = \frac{\bar{X}_n - \mu_0}{S_n/\sqrt{n}} \sim t(n-1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right). \quad (8.8)$$

Introduciamo il valore $t_{n-1, \alpha}$ tale che

$$\mathbb{P}(\{T_{n-1} > t_{n-1, \alpha}\}) = \alpha.$$




FIGURA 8.15. Coda destra della legge t-Student con probabilità α .

Allora, scegliendo

$$\frac{\delta}{S_n/\sqrt{n}} = z_\alpha \implies \delta = \frac{S_n}{\sqrt{n}} z_\alpha,$$

otteniamo (8.8).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{s_n}{\sqrt{n}}t_{n-1,\alpha}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{s_n}{\sqrt{n}}t_{n-1,\alpha}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.31. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione t-Student tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{s_n}{\sqrt{n}}t_{n-1,\alpha} \right\}.$$

8.3.5.3. *Test unilaterale destro su μ (variante)*. Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \leq \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se la media è sufficientemente più grande di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \leq \mu_0$.

OSSERVAZIONE 8.32. Attenzione: se $\mu \leq \mu_0$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ come prima. Il valore della media della popolazione è μ , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\mu \leq \mu_0$

$$\bar{X}_n > \mu_0 + \delta \implies \bar{X}_n > \mu + \delta.$$


Utilizziamo questo per il calcolo della regione critica. \square

Non è nota σ^2 , quindi verrà stimata dalla varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$, dove $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ è la media campionaria. Abbiamo che

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) \leq \mathbb{P}(\{\bar{X}_n > \mu + \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right), \end{aligned}$$

dove $T_{n-1} = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \sim t(n-1)$ poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti. Introduciamo il valore $t_{n-1,\alpha}$ tale che

$$\mathbb{P}(\{T_{n-1} > t_{n-1,\alpha}\}) = \alpha.$$

FIGURA 8.16. Coda destra della legge t-Student con probabilità α .

Allora, scegliendo

$$\frac{\delta}{S_n/\sqrt{n}} = t_{n-1, \alpha} \implies \delta = \frac{S_n}{\sqrt{n}} t_{n-1, \alpha},$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.33. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione t-Student tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\}.$$

8.3.5.4. *Test unilaterale sinistro su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficiente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$. Quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$. Non è nota σ^2 , quindi verrà stimata dalla varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$, dove $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ è la media campionaria. Abbiamo che:

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{S_n/\sqrt{n}} < -\frac{\delta}{S_n/\sqrt{n}}\right\}\right).$$

Poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ indipendenti, si ha che $T_{n-1} = \frac{\bar{X}_n - \mu_0}{S_n/\sqrt{n}} \sim t(n-1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{T_{n-1} < -\frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right). \quad (8.9)$$

Introduciamo il valore $t_{n-1, \alpha}$ tale che

$$\mathbb{P}(\{T_{n-1} > t_{n-1, \alpha}\}) = \alpha.$$




FIGURA 8.17. Coda sinistra della legge t-Student con probabilità α .

Allora, scegliendo

$$\frac{\delta}{S_n/\sqrt{n}} = t_{n-1, \alpha} \implies \delta = \frac{S_n}{\sqrt{n}} t_{n-1, \alpha},$$

otteniamo (8.9).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.34. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione t -Student tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{s_n}{\sqrt{n}} t_{n-1, \alpha} \right\}.$$

8.3.5.5. *Test unilaterale sinistro su μ (variante)*. Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \geq \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficientemente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \geq \mu_0$.

OSSERVAZIONE 8.35. Attenzione: se $\mu \geq \mu_0$, non è detto che $X_1, \dots, X_n \sim \mathcal{N}(\mu_0, \sigma^2)$ come prima. Il valore della media della popolazione è μ , quindi $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$. Tuttavia, poiché $\mu \geq \mu_0$

$$\bar{X}_n < \mu_0 - \delta \implies \bar{X}_n < \mu - \delta.$$


Utilizziamo questo per il calcolo della regione critica. □

Non è nota σ^2 , quindi verrà stimata dalla varianza campionaria $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$, dove $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ è la media campionaria. Abbiamo che:

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) \leq \mathbb{P}(\{\bar{X}_n < \mu - \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} < -\frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} < -\frac{\delta}{S_n/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{T_{n-1} > \frac{\delta}{S_n/\sqrt{n}}\right\}\right), \end{aligned}$$

dove $T_{n-1} = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}} \sim t(n-1)$ poiché $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ indipendenti. Introduciamo il valore $t_{n-1, \alpha}$ tale che

$$\mathbb{P}(\{T_{n-1} > t_{n-1, \alpha}\}) = \alpha.$$

FIGURA 8.18. Coda sinistra della legge t-Student con probabilità α .

Allora, scegliendo

$$\frac{\delta}{S_n/\sqrt{n}} = t_{n-1, \alpha} \implies \delta = \frac{S_n}{\sqrt{n}} t_{n-1, \alpha},$$

otteniamo

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{S_n}{\sqrt{n}} t_{n-1, \alpha}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.36. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è possibile definire il p -value dei dati e calcolarlo con software, ma le tavole della distribuzione t-Student tipicamente non sono sufficienti perché contengono solo una selezione di valori di probabilità.

$$p\text{-value} = \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{S_n}{\sqrt{n}} t_{n-1, \alpha} \right\}.$$

8.3.6. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 8.37. Un articolo dell'*ASCE Journal of Energy Engineering* (1999, Vol. 125, pp. 59–75) descrive uno studio sulle proprietà di inerzia termica del calcestruzzo aerato autoclavato utilizzato come materiale da costruzione. Cinque campioni del materiale sono stati testati in una struttura e la temperatura interna media ($^{\circ}\text{C}$) riportata era la seguente: 23.01, 22.22, 22.04, 22.62 e 22.59. Testare le ipotesi $H_0 : \mu = 22.5$ contro $H_1 : \mu \neq 22.5$

utilizzando significatività 5% e supponendo che la distribuzione della temperatura interna sia normale. \square

ESERCIZIO 8.38. Un'azienda che produce sigarette dichiara che il contenuto di catrame delle sigarette prodotte è in media uguale a 6 mg. Si vuole controllare la dichiarazione del produttore e si misura il contenuto di catrame in un campione:

6.9 7.4 7.3 6.6 7.0 6.7 7.1 6.2 7.2 6.6 6.9 6.5 7.2 7.7 7.5.

Si assuma la distribuzione del catrame normale. I dati sono significativi al 5% per stabilire che in realtà la media è più alta? \square

ESERCIZIO 8.39. Un produttore afferma che la carica media di un certo tipo di batterie è maggiore o uguale a 240 ampere-ora. Un campione di 18 batterie di questo tipo che è stato analizzato ha fornito i valori seguenti:

237 242 244 262 225 218 242 248 243
234 236 228 232 230 254 220 232 240

Assumendo che la distribuzione della carica sia normale, si può rifiutare l'affermazione del produttore con un livello di significatività del 5%? \square

8.3.7. Campione numeroso, μ incognita, σ^2 nota: test su μ . Consideriamo una popolazione $X: \Omega \rightarrow \mathbb{R}$ (non necessariamente normale) con $\mathbb{E}(X) = \mu$ e $\text{Var}(X) = \sigma^2$ e un campione casuale X_1, \dots, X_n estratto dalla popolazione con $n \geq 30$. Supponiamo che σ^2 sia nota (es.: si sa *a priori* che $\sigma^2 = 1$).

8.3.7.1. *Test bilaterale su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0: \mu = \mu_0, \quad H_1: \mu \neq \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1: \mu \neq \mu_0$, i dati saranno significativi se la media è sufficientemente distante da μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$, ovvero $\mathbb{E}(X_i) = \mu_0$. Consideriamo la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ e utilizziamo la definizione di significatività per ottenere

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{|\bar{X}_n - \mu_0| > \delta\}) = \mathbb{P}\left(\left\{\frac{|\bar{X}_n - \mu_0|}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Non conosciamo la distribuzione della popolazione, ma il campione è numeroso ($n \geq 30$). Per il Teorema del Limite Centrale, si ha che $\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow +\infty} Z$ in legge, dove $Z \sim \mathcal{N}(0, 1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{\frac{|\bar{X}_n - \mu_0|}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \simeq \mathbb{P}\left(\left\{|Z| > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Per la simmetria della gaussiana

$$\begin{aligned}\alpha &\simeq \mathbb{P}\left(\left\{|Z| > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) + \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \\ &= 2\mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right),\end{aligned}\tag{8.10}$$

da cui

$$\mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \frac{\alpha}{2}.$$

Introduciamo il valore $z_{\alpha/2}$ tale che

$$\mathbb{P}\left(\left\{Z > z_{\alpha/2}\right\}\right) = \frac{\alpha}{2}.$$




FIGURA 8.19. Code della legge normale con probabilità $\frac{\alpha}{2}$.

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_{\alpha/2} \implies \delta = \frac{\sigma}{\sqrt{n}} z_{\alpha/2},$$

otteniamo (8.10).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : |\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right\},$$

e decidiamo come segue:

- Se $|\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2}$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $|\bar{x}_n - \mu_0| \leq \frac{\sigma}{\sqrt{n}} z_{\alpha/2}$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente

crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : |\bar{x}_n - \mu_0| > \frac{\sigma}{\sqrt{n}} z_{\alpha/2} \right\} = \inf \left\{ \alpha : \frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} > z_{\alpha/2} \right\} \\ &= \inf \left\{ \alpha : \Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) > \Phi(z_{\alpha/2}) \right\} = \inf \left\{ \alpha : \Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) > 1 - \frac{\alpha}{2} \right\} \\ &= \inf \left\{ \alpha : \alpha > 2 - 2\Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right) \right\} = 2 - 2\Phi \left(\frac{|\bar{x}_n - \mu_0|}{\sigma/\sqrt{n}} \right). \end{aligned}$$

8.3.7.2. *Test unilaterale destro su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se sufficientemente più grandi di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$, ovvero $\mathbb{E}(X_i) = \mu_0$. Consideriamo la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ e utilizziamo la definizione di significatività per ottenere

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Non conosciamo la distribuzione della popolazione, ma il campione è numeroso ($n \geq 30$). Per il Teorema del Limite Centrale, si ha che $\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow +\infty} Z$ in legge, dove $Z \sim \mathcal{N}(0, 1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \simeq \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.20. Coda destra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (8.2).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.40. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} > z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > \Phi(z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > 1 - \alpha \right\} \\ &= \inf \left\{ \alpha : \alpha > 1 - \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) \right\} = 1 - \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.7.3. *Test unilaterale destro su μ (variante)*. Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \leq \mu_0, \quad H_1 : \mu > \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu > \mu_0$, i dati saranno significativi se la media è sufficientemente più grande di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \leq \mu_0$.

OSSERVAZIONE 8.41. Attenzione: se $\mu \leq \mu_0$, non è detto che $\mathbb{E}(X_i) = \mu_0$ come prima. Il valore della media della popolazione è μ , quindi $\mathbb{E}(X_i) = \mu$. Tuttavia, poiché $\mu \leq \mu_0$

$$\bar{X}_n > \mu_0 + \delta \implies \bar{X}_n > \mu + \delta.$$

Utilizziamo questo per il calcolo della regione critica. \square

Utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n > \mu_0 + \delta\}) \leq \mathbb{P}(\{\bar{X}_n > \mu + \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right), \end{aligned}$$

Non conosciamo la distribuzione della popolazione, ma il campione è numeroso ($n \geq 30$). Per il Teorema del Limite Centrale, si ha che $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow +\infty} Z$ in legge, dove $Z \sim \mathcal{N}(0, 1)$. Quindi

$$\mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \simeq \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.21. Coda destra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (approssimativamente)

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è approssimativamente più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \leq \mu_0 + \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.42. Questo tipo di test ha senso solo quando $\bar{x}_n > \mu_0$. Se $\bar{x}_n \leq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu > \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 > \frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} > z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) > \Phi(z_\alpha) \right\} = \inf \left\{ \alpha : \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) > 1 - \alpha \right\} \\ &= \inf \left\{ \alpha : \alpha > 1 - \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right) \right\} = 1 - \Phi \left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} \right). \end{aligned}$$

8.3.7.4. *Test unilaterale sinistro su μ .* Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu = \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficiente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu = \mu_0$, ovvero $\mathbb{E}(X_i) = \mu_0$. Consideriamo la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ e utilizziamo la definizione di significatività per ottenere

$$\alpha = \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) = \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right).$$

Non conosciamo la distribuzione della popolazione, ma il campione è numeroso ($n \geq 30$). Per il Teorema del Limite Centrale, si ha che $\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow +\infty} Z$ in legge, dove $Z \sim \mathcal{N}(0, 1)$. Quindi

$$\alpha = \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \simeq \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right). \quad (8.11)$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.22. Coda sinistra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (8.11).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.43. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} < -z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \Phi(-z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \alpha \right\} \\ &= \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.7.5. Test unilaterale sinistro su μ (variante). Sia μ_0 un valore fissato. Consideriamo il seguente test di ipotesi

$$H_0 : \mu \geq \mu_0, \quad H_1 : \mu < \mu_0,$$

con livello di significatività α .

Poiché l'ipotesi alternativa è $H_1 : \mu < \mu_0$, i dati saranno significativi se la media è sufficientemente più piccola di μ_0 . La regione critica è allora della forma

$$R_c = \{(x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \delta\},$$

dove $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ è la media calcolata sulla realizzazione x_1, \dots, x_n del campione casuale.

Assumiamo l'ipotesi nulla H_0 vera, cioè $\mu \geq \mu_0$.

OSSERVAZIONE 8.44. Attenzione: se $\mu \geq \mu_0$, non è detto che $\mathbb{E}(X_i) = \mu_0$ come prima. Il valore della media della popolazione è μ , quindi $\mathbb{E}(X_i) = \mu$. Tuttavia, poiché $\mu \geq \mu_0$

$$\bar{X}_n < \mu_0 - \delta \implies \bar{X}_n < \mu - \delta.$$

Utilizziamo questo per il calcolo della regione critica. □

Utilizzando la media campionaria $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$,

$$\begin{aligned} \mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) &= \mathbb{P}(\{\bar{X}_n < \mu_0 - \delta\}) \leq \mathbb{P}(\{\bar{X}_n < \mu - \delta\}) \\ &= \mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right), \end{aligned}$$

Non conosciamo la distribuzione della popolazione, ma il campione è numeroso ($n \geq 30$). Per il Teorema del Limite Centrale, si ha che $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \xrightarrow{n \rightarrow +\infty} Z$ in legge, dove $Z \sim \mathcal{N}(0, 1)$. Quindi

$$\mathbb{P}\left(\left\{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) \simeq \mathbb{P}\left(\left\{Z < -\frac{\delta}{\sigma/\sqrt{n}}\right\}\right) = \mathbb{P}\left(\left\{Z > \frac{\delta}{\sigma/\sqrt{n}}\right\}\right),$$

Introduciamo il valore z_α tale che

$$\mathbb{P}(\{Z > z_\alpha\}) = \alpha.$$




FIGURA 8.23. Coda sinistra della legge normale con probabilità α .

Allora, scegliendo

$$\frac{\delta}{\sigma/\sqrt{n}} = z_\alpha \implies \delta = \frac{\sigma}{\sqrt{n}} z_\alpha,$$

otteniamo (approssimativamente)

$$\mathbb{P}(\{(X_1, \dots, X_n) \in R_c\}) \leq \alpha,$$

(ovvero la probabilità di commettere un errore del I tipo è approssimativamente più piccola di α).

In conclusione, la regione critica è

$$R_c = \left\{ (x_1, \dots, x_n) \in R(X_1, \dots, X_n) : \bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha \right\},$$

e decidiamo come segue:

- Se $\bar{x}_n < \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati sono sufficientemente significativi da rifiutare H_0 . L'ipotesi nulla H_0 viene rifiutata (con livello di significatività α).
- Se $\bar{x}_n \geq \mu_0 - \frac{\sigma}{\sqrt{n}} z_\alpha$, i dati non sono sufficientemente significativi da rifiutare. L'ipotesi nulla H_0 non viene rifiutata (con livello di significatività α).

OSSERVAZIONE 8.45. Questo tipo di test ha senso solo quando $\bar{x}_n < \mu_0$. Se $\bar{x}_n \geq \mu_0$, ovviamente i dati non saranno significativi per stabilire che $\mu < \mu_0$. \square

In questo caso è anche possibile calcolare esplicitamente il p -value dei dati. Utilizzando il fatto che la funzione di distribuzione cumulativa della normale standard è strettamente crescente, otteniamo che

$$\begin{aligned} p\text{-value} &= \inf \left\{ \alpha : \bar{x}_n - \mu_0 < -\frac{\sigma}{\sqrt{n}} z_\alpha \right\} = \inf \left\{ \alpha : \frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}} < -z_\alpha \right\} \\ &= \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) < \Phi(-z_\alpha) \right\} = \inf \left\{ \alpha : \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right) > \alpha \right\} \\ &= \Phi\left(\frac{\bar{x}_n - \mu_0}{\sigma/\sqrt{n}}\right). \end{aligned}$$

8.3.8. Esercizi. Qui vengono proposti alcuni esercizi per consolidare l'apprendimento dei concetti appena spiegati.

ESERCIZIO 8.46. La vita media calcolata su un campione di 100 lampadine fluorescenti prodotte da un'azienda è 1570 ore la deviazione standard della popolazione è di 120 ore. Se μ è la vita media di tutte le lampadine prodotte dall'azienda, verificare l'ipotesi $\mu = 1600$ ore contro l'ipotesi alternativa $\mu \neq 1600$ ore, utilizzando un livello di significatività di (a) 0.05 e (b) 0.01. (c) Trovare il p -value del test. \square

ESERCIZIO 8.47. Il/la docente di Probabilità e Statistica vuole un'evidenza significativa del fatto che in questo anno accademico l'esame sia stato più difficile per gli studenti e le studentesse.¹ Negli anni accademici precedenti, la media dei voti era 24. In un appello di questo anno accademico, invece, sono stati registrati i seguenti voti:

21 26 23 25 18 24 18 28 23 26 20 20 18 20 21 20
30 25 19 23 26 26 26 26 29 28 25 18 21 26 18 27

(La media calcolata sui dati del campione risulta essere 23.25.) Si sa che la deviazione standard dei voti è $\sigma = 3.5$.

¹L'esercizio è inventato e ogni riferimento a persone o fatti realmente accaduti è puramente casuale.

- (1) I voti assegnati nell'ultimo appello sono significativi al 5% per concludere che la media è effettivamente più bassa rispetto agli anni precedenti? (N.B.: ricavare le formule)
- (2) Qual è il più piccolo livello di significatività per cui i dati permettono di affermare che la media è effettivamente più bassa?

□




FIGURA 8.24. *xkcd* 882. SIGNIFICANT. Credits: <https://xkcd.com/882/>

APPENDICE A

Schema riassuntivo delle variabili aleatorie

Contenuti

A.1.	Legge di Bernoulli	226
A.2.	Legge binomiale	227
A.3.	Legge di Poisson	228
A.4.	Legge geometrica	229
A.5.	Legge uniforme	230
A.6.	Legge normale	231
A.7.	Legge esponenziale	232
A.8.	Legge Gamma	233
A.9.	Legge chi-quadro	234
A.10.	Legge t-Student	235

A.1. Legge di Bernoulli

Simbolo: $X \sim \text{Be}(p)$.

Significato: Successo/Insuccesso.

Parametri: p : probabilità di un successo.

Range: $R(X) = \{0, 1\}$.

Legge: Si ha che

$$\mathbb{P}(\{X = 1\}) = p, \quad \mathbb{P}(\{X = 0\}) = 1 - p.$$

Valore atteso: $\mathbb{E}(X) = p$.

Varianza: $\text{Var}(X) = p(1 - p)$.

A.2. Legge binomiale

Simbolo: $X \sim B(n, p)$.

Significato: Numero di successi in prove indipendenti.

Parametri: n : numero di prove indipendenti; p : probabilità di un singolo successo.

Range: $R(X) = \{0, 1, \dots, n\}$.

Legge: Si ha che

$$\mathbb{P}(\{X = k\}) = \binom{n}{k} p^k (1-p)^{n-k} = \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k},$$

per $k = 0, 1, \dots, n$.

Valore atteso: $\mathbb{E}(X) = np$.

Varianza: $\text{Var}(X) = np(1-p)$.

Alcune proprietà:

- Se $X_1, \dots, X_n \sim \text{Be}(p)$ indipendenti, allora $X = X_1 + \dots + X_n \sim B(n, p)$.
- Se $X \sim B(n, p)$ e $Y \sim B(m, p)$ indipendenti, allora $X + Y \sim B(n + m, p)$.

A.3. Legge di Poisson

Simbolo: $X \sim P(\lambda)$.

Significato: Numero di successi in tante prove indipendenti con piccola probabilità di successo.

Parametri: λ : media dei successi.

Range: $R(X) = \{0, 1, 2, \dots\} = \mathbb{N}$.

Legge: Si ha che

$$\mathbb{P}(\{X = k\}) = e^{-\lambda} \frac{\lambda^k}{k!},$$

per $k \in \mathbb{N}$.

Valore atteso: $\mathbb{E}(X) = \lambda$.

Varianza: $\text{Var}(X) = \lambda$.

Alcune proprietà:

- Il termine $\frac{\lambda^k}{k!}$ è il k -esimo termine nello sviluppo di Taylor di e^λ .
- La costante $e^{-\lambda}$ fa sì che $\sum_{k=0}^{+\infty} e^{-\lambda} \frac{\lambda^k}{k!} = 1$.
- La legge di Poisson si ottiene dal limite di leggi binomiali. Se $X_n \sim B(n, p_n)$ con $np_n = \lambda$ e $X \sim P(\lambda)$, allora $\lim_{n \rightarrow +\infty} \mathbb{P}(\{X_n = k\}) = \mathbb{P}(\{X = k\})$ per $k \in \mathbb{N}$.
- Se $X \sim P(\lambda)$ e $Y \sim P(\mu)$ indipendenti, allora $X + Y \sim P(\lambda + \mu)$.

A.4. Legge geometrica

Simbolo: $X \sim \text{Geo}(p)$.

Significato: Primo successo in tante prove indipendenti.

Parametri: p : probabilità di un singolo successo.

Range: $R(X) = \{1, 2, \dots\} = \mathbb{N} \setminus \{0\}$.

Legge: Si ha che

$$\mathbb{P}(\{X = k\}) = (1 - p)^{k-1}p,$$

per $k \in \mathbb{N} \setminus \{0\}$.

Valore atteso: $\mathbb{E}(X) = \frac{1}{p}$.

Varianza: $\text{Var}(X) = \frac{1-p}{p^2}$.

Alcune proprietà:

- Utilizzando la serie geometrica si dimostra che $\sum_{k=1}^{+\infty} (1 - p)^{k-1}p = 1$.
- $\mathbb{P}(\{X > k\}) = (1 - p)^k$.
- Assenza di memoria.

A.5. Legge uniforme

Simbolo: $X \sim U(a, b)$.

Significato: Gli intervalli della stessa ampiezza interamente contenuti in $[a, b]$ sono tutti equiprobabili.

Parametri: a, b : estremi dell'intervallo.

Range: $R(X) = [a, b] = \{x \in \mathbb{R} : a \leq x \leq b\}$.

Legge: La densità è data da

$$f_X(x) = \begin{cases} \frac{1}{b-a}, & \text{se } x \in [a, b], \\ 0, & \text{altrimenti.} \end{cases}$$

Valore atteso: $\mathbb{E}(X) = \frac{a+b}{2}$.

Varianza: $\text{Var}(X) = \frac{(b-a)^2}{12}$.

A.6. Legge normale

Simbolo: $X \sim \mathcal{N}(\mu, \sigma^2)$.

Significato: La legge più importante di tutte. Compare nel Teorema del Limite Centrale.

Parametri: μ : media; σ^2 : varianza.

Range: $R(X) = \mathbb{R}$.

Legge: La densità è data da

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} dx$$

per $x \in \mathbb{R}$.

Valore atteso: $\mathbb{E}(X) = \mu$.

Varianza: $\text{Var}(X) = \sigma^2$.

Alcune proprietà:

- μ è il massimo della f_X , $\mu \pm \sigma$ sono i punti di flesso di f_X .
- La costante $\sqrt{2\pi}$ si ottiene con un trucco: per ottenere il quadrato dell'integrale della curva gaussiana, si integra in coordinate polari in due dimensioni.
- Se $X \sim \mathcal{N}(\mu, \sigma^2)$, allora $aX + b \sim \mathcal{N}(a\mu + b, a^2\sigma^2)$.
- Se $X \sim \mathcal{N}(\mu, \sigma^2)$ e $Y \sim \mathcal{N}(\nu, \tau^2)$ indipendenti, allora $X + Y \sim \mathcal{N}(\mu + \nu, \sigma^2 + \tau^2)$.
- La tavola della funzione di distribuzione cumulativa della normale standard raccoglie i valori di $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{1}{2}t^2} dt$.
- Vale il Teorema del Limite Centrale.

A.7. Legge esponenziale

Simbolo: $X \sim \text{Exp}(\lambda)$.

Significato: Tempi di attesa con assenza di memoria.

Parametri: λ : peso del decadimento esponenziale o reciproco della media.

Range: $R(X) = (0, +\infty)$.

Legge: La densità è data da

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{se } x > 0, \\ 0 & \text{altrimenti.} \end{cases}$$

Valore atteso: $\mathbb{E}(X) = \frac{1}{\lambda}$.

Varianza: $\text{Var}(X) = \frac{1}{\lambda^2}$.

Alcune proprietà:

- $\mathbb{P}(\{X > t\}) = e^{-\lambda t}$.
- Assenza di memoria.

A.8. Legge Gamma

Simbolo: $X \sim \text{Gamma}(\alpha, \lambda)$.

Significato: Generalizzazione dell'esponenziale. Può essere interpretata come una legge esponenziale sommata α volte (quando α è un numero naturale).

Parametri: α : numero di leggi esponenziale sommate (quando α è un numero naturale); λ : peso del decadimento esponenziale.

Range: $R(X) = (0, +\infty)$.

Legge: La densità è data da

$$f_X(x) = \begin{cases} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}, & \text{se } x > 0, \\ 0 & \text{altrimenti,} \end{cases}$$

dove Γ è la funzione Gamma di Eulero.

Valore atteso: $\mathbb{E}(X) = \frac{\alpha}{\lambda}$.

Varianza: $\text{Var}(X) = \frac{\alpha}{\lambda^2}$.

Alcune proprietà:

- $\text{Gamma}(1, \lambda) = \text{Exp}(\lambda)$.
- Ricordiamo che la funzione Gamma di Eulero estende il fattoriale. Infatti $\Gamma(\alpha) = (\alpha - 1)\Gamma(\alpha - 1)$.
- $\Gamma(1) = 1$.
- $\Gamma(\frac{1}{2}) = \sqrt{\pi}$.
- Se $X \sim \text{Gamma}(\alpha, \lambda)$ e $Y \sim \text{Gamma}(\beta, \lambda)$ indipendenti, allora $X + Y \sim \text{Gamma}(\alpha + \beta, \lambda)$.
- Se $X_1, \dots, X_n \sim \text{Exp}(\lambda)$ indipendenti, allora $X = X_1 + \dots + X_n \sim \text{Gamma}(n, \lambda)$.

A.9. Legge chi-quadro

Simbolo: $Q_n \sim \chi^2(n)$.

Significato: Somma dei quadrati di n normali standard indipendenti. È la distribuzione di $\frac{(n-1)S_n^2}{\sigma^2}$ dove S_n^2 è la varianza campionaria di un campione casuale estratto da una popolazione normale.

Parametri: n : gradi di libertà, ovvero numero delle n normali standard indipendenti.

Range: $R(Q_n) = (0, +\infty)$.

Legge: Si osserva che $\chi^2(n) = \text{Gamma}(\frac{n}{2}, \frac{1}{2})$. Quindi la densità è data da

$$f_{Q_n}(x) = \begin{cases} \frac{1}{\Gamma(\frac{n}{2})2^{\frac{n}{2}}} x^{\frac{n}{2}-1} e^{-\frac{1}{2}x}, & \text{se } x > 0, \\ 0 & \text{altrimenti,} \end{cases}$$

dove Γ è la funzione Gamma di Eulero.

Valore atteso: $\mathbb{E}(Q_n) = n$.

Varianza: $\text{Var}(Q_n) = 2n$.

Alcune proprietà:

- $Q_n = Z_1^2 + \dots + Z_n^2$ dove $Z_1, \dots, Z_n \sim \mathcal{N}(0, 1)$ indipendenti.
- Possiamo calcolare $\Gamma(\frac{n}{2})$ utilizzando la formula ricorsiva $\Gamma(\frac{n}{2}) = (\frac{n}{2} - 1)\Gamma(\frac{n}{2} - 1)$ fino ad arrivare a $\Gamma(\frac{1}{2}) = \sqrt{\pi}$.
- I valori $\chi_{\alpha, n}^2$ tali che $\mathbb{P}(\{Q_n \geq \chi_{\alpha, n}^2\}) = \alpha$ sono raccolti nella tavola della distribuzione chi-quadro.

A.10. Legge t-Student

Simbolo: $T_n \sim t(n)$.

Significato: Si ottiene da $\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}}$ per un campione casuale $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$.

Parametri: n : gradi di libertà, ovvero numero delle n normali standard indipendenti.

Range: $R(T_n) = \mathbb{R}$.

Legge: La densità è data da

$$f_{T_n}(x) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})} \frac{1}{(1 + \frac{x^2}{n})^{\frac{n+1}{2}}},$$

dove Γ è la funzione Gamma di Eulero.

Valore atteso: $\mathbb{E}(T_n) = 0$.

Varianza: $\text{Var}(T_n) = \frac{n}{n-2}$ se $n > 2$ (non l'abbiamo calcolata).

Alcune proprietà:

- I valori $t_{\alpha,n}$ tali che $\mathbb{P}(\{T_n \geq t_{\alpha,n}\}) = \alpha$ sono raccolti nella tavola della distribuzione t-Student.

Lista dei simboli

Legenda

-  ATTENZIONE!
-  commento su fogli di calcolo
-  spiegazione di un passaggio in una formula
-  approfondimento per chi ha più interesse nella materia
-  link a video divulgativo
-  link a grafico interattivo
-  link a slide animata

Simboli matematici

- $\{a, b, c\}$ insieme costituito dagli elementi a, b, c
- $A \setminus B$ insieme costituito dagli elementi di A a cui vengono rimossi gli elementi di B
- $\#A$ numero degli elementi dell'insieme A
- $|A|$ misura dell'insieme A
- \simeq approssimativamente uguale a
- $:=$ definito da
- $v \cdot w$ prodotto scalare tra i vettori v e w
- $|v|$ norma del vettore v




FIGURA A.1. *xkcd* 557. STUDENTS. Credits: <https://xkcd.com/557/>

Bibliografia

- [1] F. Caravenna e P. Dai Pra. *Probabilità. Un'introduzione attraverso modelli e applicazioni*. Springer-Verlag Italia Srl., 2013.
- [2] Y. Dodge. *The Concise Encyclopedia of Statistics*. Springer Science+Business Media, 2008.
- [3] D. C. Montgomery e G. C. Runger. *Applied Statistics and Probability for Engineers*. John Wiley & Sons, Inc., 2003.
- [4] D. C. Montgomery, G. C. Runger e N. F. Hubele. *Statistica per ingegneria*. EGEA, 2012.
- [5] S. M. Ross. *Introduction to Probability and Statistics for Engineers and Scientists*. Elsevier Academic Press, 2009.
- [6] S. M. Ross. *Probabilità e statistica per l'ingegneria e le scienze*. Maggioli Editore, 2013.