



UNIVERSITÀ
DEGLI STUDI
DI TRIESTE



Dipartimento di
Ingegneria
e Architettura

Corso di misure meccaniche, termiche e collaudi

Prof. Rodolfo Taccani

Prof. Lucia Parussini

Prof. Marco Bogar

a.a.2023-2024

Outline

- Presentazione dei dati
- Outliers
- Descrizione statistica dei dati
- Correlazione tra dati appaiati

Analisi dei dati

Presentazione delle serie di dati

- Tabelle e grafici di frequenza
- Tabelle e grafici di frequenza relativa
- Istogramma
- Ogiva
- Grafico a stelo e foglie

Analisi dei dati

Tabelle e grafici di frequenza

Un insieme di dati che ha un numero relativamente piccolo di valori distinti può essere convenientemente presentato in una tabella di frequenza.

Esempio:

Starting salary	Frequency
47	4
48	1
49	3
50	5
51	8
52	10
53	0
54	5
56	2
57	3
60	1

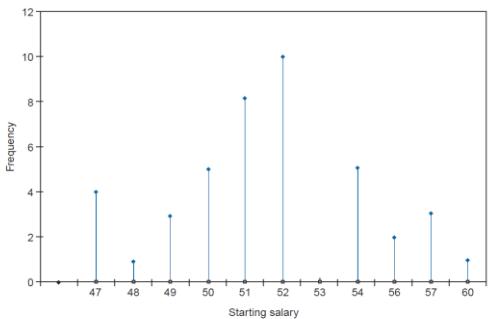
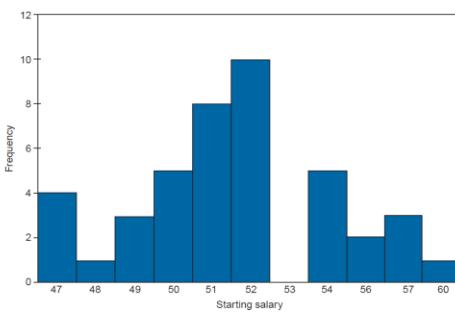
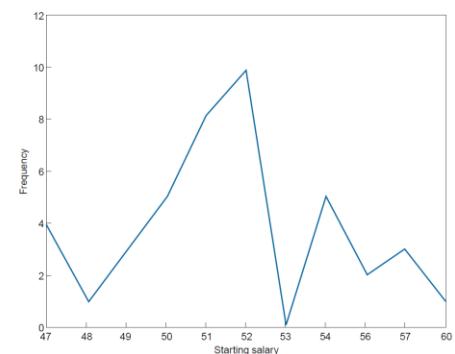


Grafico lineare.



Istogramma.



Poligono di frequenza.

Analisi dei dati

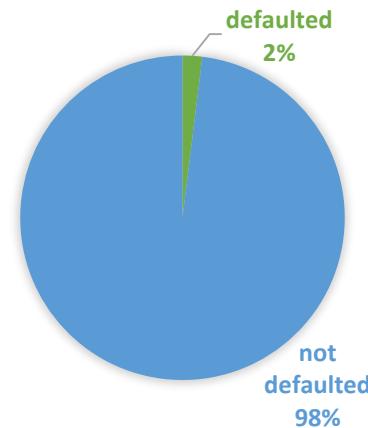
Tabelle e grafici di frequenza relativa

Si consideri un insieme di dati composto da n valori. Se f è la frequenza di un particolare valore, allora il rapporto f/n è chiamato la sua frequenza relativa.

Esempi:

Starting salary	Relative frequency
47	$4/42 = 0.0952$
48	$1/42 = 0.0238$
49	$3/42 = 0.0714$
50	$5/42 = 0.119$
51	$8/42 = 0.1905$
52	$10/42 = 0.2381$
53	$0/42 = 0$
54	$5/42 = 0.119$
56	$2/42 = 0.0476$
57	$3/42 = 0.0714$
60	$1/42 = 0.0238$

Type of result	Frequency	Relative frequency
defaulted	20	0.020
not defaulted	1000	0.980



Analisi dei dati

Istogramma

Per serie di dati in cui il numero di valori distinti è grande, è utile dividere i valori in raggruppamenti, o intervalli di classe, e poi tracciare il numero di valori di dati che rientrano in ogni intervallo di classe.

Gli **istogrammi** consentono di aggregare dati numerici in gruppi di intervalli uguali. Agli intervalli viene spesso dato il nome di bin. Ci sono due regole alternative per calcolare il miglior numero di bin da usare:

La **regola di Sturgis** calcola il numero di bande come:

$$\text{Number of bins} = 1 + 3.3 \log_{10}(n)$$

dove n è il numero di valori misurati.

La **regola di Rice** calcola il numero di bande come:

$$\text{Number of bins} = 2n^{1/3}$$

Ovviamente il risultato prodotto deve essere arrotondato al numero intero più vicino in entrambi i casi.

Analisi dei dati

Istogramma

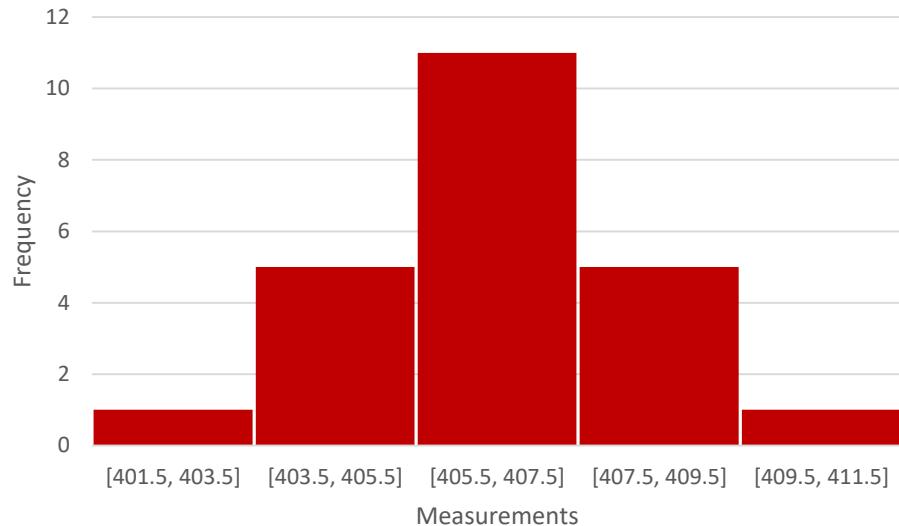
Number of measurements	Number of bins calculated by Sturgis rule	Number of bins by Sturgis (rounded)	Number of bins calculated by Rice rule	Number of bins by Rice (rounded)
10	4.30	4	4.31	4
15	4.88	5	4.93	5
20	5.29	5	5.43	5
25	5.61	6	5.85	6
30	5.87	6	6.21	6
50	6.61	7	7.37	7
100	7.60	8	9.28	9
200	8.59	9	11.70	12

Analisi dei dati

Istogramma

Esempio: Disegna un istogramma per le 23 misure di lunghezza [mm] del set di dati.

numero misura	valore misura	numero misura	valore misura	numero misura	valore misura
1	409	10	407	19	406
2	406	11	408	20	405
3	402	12	406	21	409
4	407	13	410	22	406
5	405	14	406	23	407
6	404	15	405		
7	407	16	408		
8	404	17	406		
9	407	18	409		

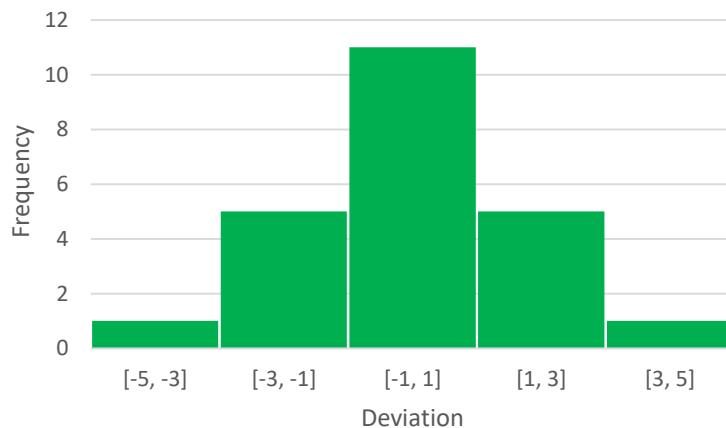


Analisi dei dati

Iistogramma

Esempio: Disegna un istogramma per le 23 misure di lunghezza [mm] del set di dati.

E' spesso più utile disegnare un istogramma delle deviazioni delle misure dal valore medio piuttosto che disegnare un istogramma delle misure stesse.



Analisi dei dati

Istogramma

Esempio: durata di vita di 200 lampade a incandescenza in ore.

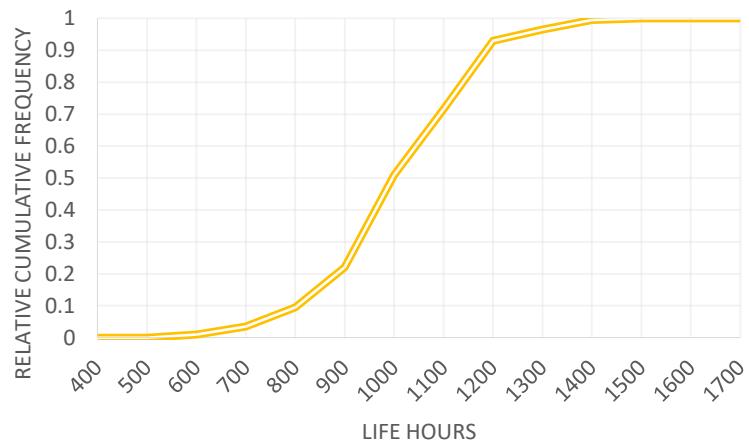
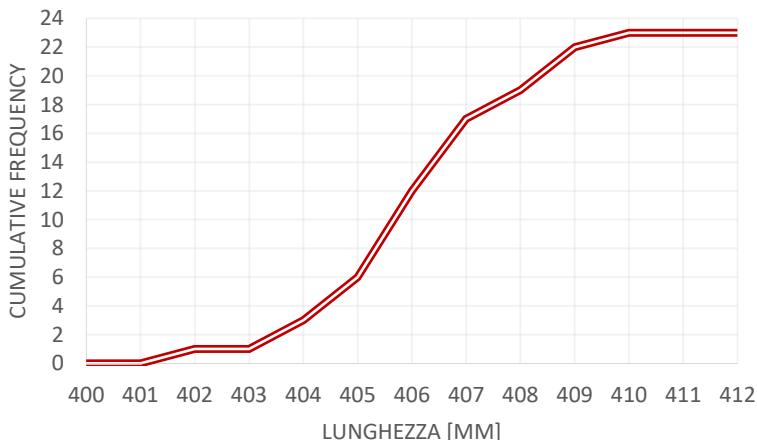
Class interval	Frequency
500-600	2
600-700	5
700-800	12
800-900	25
900-1000	58
1000-1100	41
1100-1200	43
1200-1300	7
1300-1400	6
1400-1500	1



Analisi dei dati

Ogiva o grafico di frequenza cumulativa

Un punto sull'asse orizzontale di tale grafico rappresenta un possibile valore dei dati; il suo corrispondente valore sull'asse verticale fornisce il numero dei dati i cui valori sono inferiori o uguali ad esso.



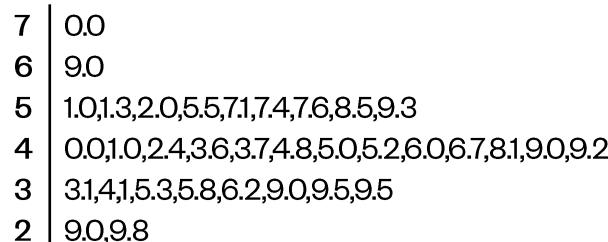
Analisi dei dati

Grafico a stelo e foglie

E' un modo efficiente di organizzare una serie di dati di piccole e medie dimensioni. Si ottiene dividendo prima ogni valore di dati in due parti - il suo gambo e la sua foglia. Per esempio, se i dati sono tutti numeri a due cifre, allora potremmo lasciare che la parte del gambo di un valore di dati sia la sua cifra delle decine e che la foglia sia la sua cifra delle unità. Così, per esempio, il valore 62 è espresso come

Stelo	Foglia
6	2

Esempio: Le temperature minime medie giornaliere annuali in 35 città degli Stati Uniti possono essere rappresentate nel seguente grafico a stelo e foglie.



Analisi dei dati

Outlier

E' un termine utilizzato in statistica per definire, in un insieme di osservazioni, un valore anomalo e aberrante, ossia un valore chiaramente distante dalle altre osservazioni disponibili. Nel campo dell'analisi sperimentale è frequente trovare, in una serie di misure, qualche dato che **non concorda con gli altri**.

In questi casi è prassi comune scartare queste misurazioni errate. Un livello di soglia spesso usato per determinare cosa dovrebbe essere scartato è $\pm 3\sigma$.

L'implementazione pratica di una tale procedura deve essere fatta con attenzione.

Analisi dei dati

Outlier

Esempio:

Viene effettuata una serie di misurazioni con un nuovo trasduttore di pressione. L'ispezione di un istogramma delle prime 20 misurazioni non mostra dati anomali. Non si osservano dati anomali.

$$\mu = 4.41 \text{ bar} \quad \sigma = 0.05 \text{ bar}$$

Viene effettuata un'ulteriore serie di misurazioni:

4.35 4.46 4.39 4.34 4.41 4.52 4.44 4.37 4.41 4.33 4.39 4.47 4.42 4.59 4.45 4.38 4.43 4.36 4.48 4.45

Usate la soglia di $\pm 3\sigma$ per determinare se ci sono punti di dati anomali nel set di misurazione.

Soluzione

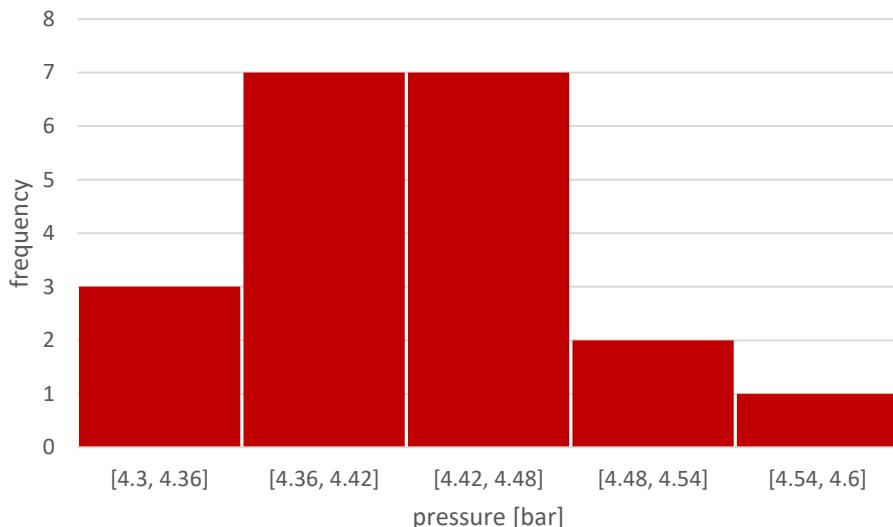
Poiché il valore σ calcolato per un insieme di buone misurazioni è 0.05 bar, la soglia $\pm 3\sigma$ è ± 0.15 . Con un valore medio dei dati di 4.41, la soglia per i punti di dati anomali è costituita da valori inferiori a 4.26 ($\mu - 3\sigma$) o superiori a 4.56 ($\mu + 3\sigma$). Guardando l'insieme delle misurazioni, osserviamo che la misura di 4.59 è al di fuori della soglia di $\pm 3\sigma$, indicando che si tratta di un dato anomalo.

4.35 4.46 4.39 4.34 4.41 4.52 4.44 4.37 4.41 4.33 4.39 4.47 4.42 4.59 4.45 4.38 4.43 4.36 4.48 4.45

Analisi dei dati

Outlier

Esempio:



4.35 4.46 4.39 4.34 4.41 4.52 4.44 4.37 4.41 4.33 4.39 4.47 4.42 4.59 4.45 4.38 4.43 4.36 4.48 4.45

E' importante garantire che non ci siano outlier nell'insieme dei dati utilizzati per calcolare la deviazione standard dei dati e quindi la soglia per rifiutare outlier.

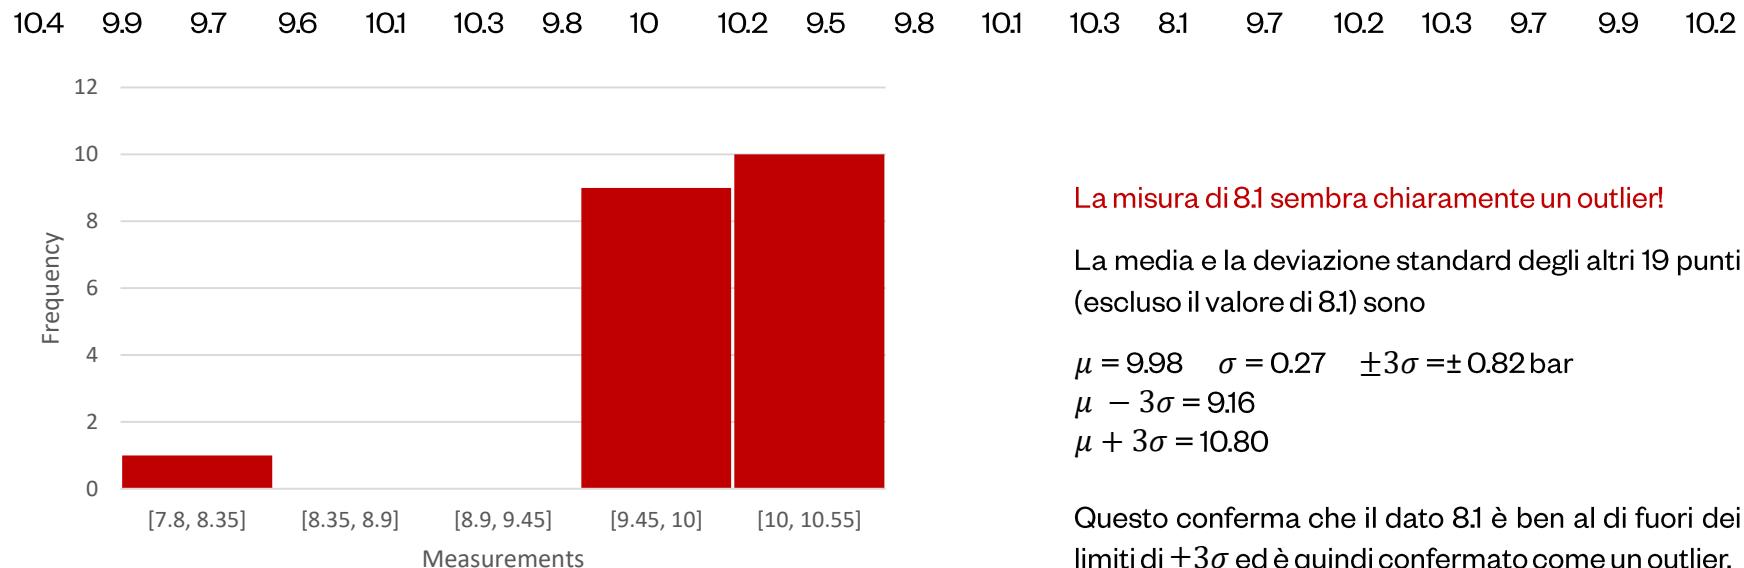
sui 19 valori escludendo la misura 4.59
 $\mu = 4.41 \text{ bar}$ $\sigma = 0.052 \text{ bar}$ $\pm 3\sigma = \pm 0.16 \text{ bar}$
 $\mu - 3\sigma = 4.25$
 $\mu + 3\sigma = 4.57$

sui 20 valori non escludendo la misura 4.59
 $\mu = 4.42 \text{ bar}$ $\sigma = 0.064 \text{ bar}$ $\pm 3\sigma = \pm 0.19 \text{ bar}$
 $\mu - 3\sigma = 4.23$
 $\mu + 3\sigma = 4.61$

Analisi dei dati

Outlier

Esempio: Consideriamo il seguente set di dati di 20 misurazioni ed esaminiamolo alla ricerca di outlier:



La misura di 8.1 sembra chiaramente un outlier!

La media e la deviazione standard degli altri 19 punti (escluso il valore di 8.1) sono

$$\mu = 9.98 \quad \sigma = 0.27 \quad \pm 3\sigma = \pm 0.82 \text{ bar}$$

$$\mu - 3\sigma = 9.16$$

$$\mu + 3\sigma = 10.80$$

Questo conferma che il dato 8.1 è ben al di fuori dei limiti di $\pm 3\sigma$ ed è quindi confermato come un outlier.

Analisi dei dati

Outlier

Criterio di Chauvenet

Consente di valutare se il dato anomalo è dovuto ad **errori grossolani** o, al contrario, se è rappresentativo di una **misura plausibile**.

In una serie di n dati sperimentali, se alcuni valori presentano uno scostamento dal valore medio che ha probabilità di verificarsi inferiore di $1/(2n)$, allora quei valori devono essere scartati.

Analisi dei dati

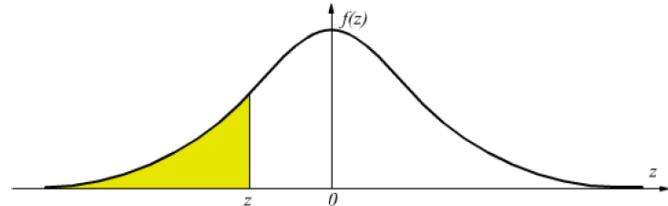
Outlier

Criterio di Chauvenet

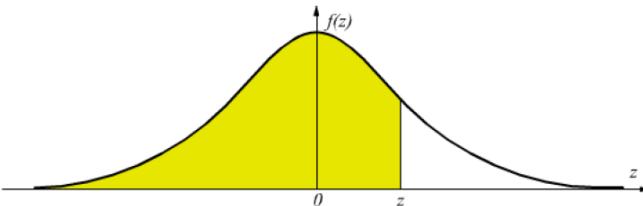
Procedimento

- 1) Si calcola la media, varianza e quindi lo scarto ridotto (o scarto standardizzato o scarto normale) dei dati $z_i = \frac{x_i - \mu}{\sigma}$
- 2) Si calcola la probabilità di Chauvenet $p_C = 1 - \frac{1}{2n}$
- 3) Si calcola la frequenza cumulata, ricordando che $p_C = 2F(z_{lim}) - 1$. Per cui $F(z_{lim}) = \frac{p_C + 1}{2}$
- 4) Si determina il valore dello scarto ridotto corrispondente al valore limite z_{lim}
- 5) Si escludono i valori per i quali il valore assoluto dello scarto ridotto è superiore a z_{lim}
- 6) Si ricalcola la media e lo scarto quadratico con i dati restanti, ma non è più lecito applicare di nuovo il criterio ai dati rimasti.

Analisi dei dati



Probabilità cumulativa per valori negativi di z



Probabilità cumulativa per valori positivi di z

z	0	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
-3,4	0,0003	0,0003	0,0003	0,0003	0,0003	0,0003	0,0003	0,0003	0,0002	
-3,3	0,0005	0,0005	0,0005	0,0004	0,0004	0,0004	0,0004	0,0004	0,0003	
-3,2	0,0007	0,0007	0,0006	0,0006	0,0006	0,0006	0,0005	0,0005	0,0005	
-3,1	0,001	0,0009	0,0009	0,0009	0,0008	0,0008	0,0008	0,0008	0,0007	0,0007
-3	0,0013	0,0013	0,0012	0,0012	0,0011	0,0011	0,0011	0,001	0,001	
-2,9	0,0019	0,0018	0,0018	0,0017	0,0016	0,0016	0,0015	0,0015	0,0014	0,0014
-2,8	0,0026	0,0025	0,0024	0,0023	0,0023	0,0022	0,0021	0,0021	0,002	0,0019
-2,7	0,0035	0,0034	0,0033	0,0032	0,0031	0,003	0,0029	0,0028	0,0027	0,0026
-2,6	0,0047	0,0045	0,0044	0,0043	0,0041	0,004	0,0039	0,0038	0,0037	0,0036
-2,5	0,0062	0,006	0,0059	0,0057	0,0055	0,0054	0,0052	0,0051	0,0049	0,0048
-2,4	0,0082	0,008	0,0078	0,0075	0,0073	0,0071	0,0069	0,0068	0,0066	0,0064
-2,3	0,0107	0,0104	0,0102	0,0099	0,0096	0,0094	0,0091	0,0089	0,0087	0,0084
-2,2	0,0139	0,0136	0,0132	0,0129	0,0125	0,0122	0,0119	0,0116	0,0113	0,011
-2,1	0,0179	0,0174	0,0174	0,017	0,0166	0,0162	0,0158	0,0154	0,015	0,0143
-2	0,0228	0,0222	0,0217	0,0212	0,0207	0,0202	0,0197	0,0192	0,0188	0,0183
-1,9	0,0287	0,0281	0,0274	0,0268	0,0262	0,0256	0,025	0,0244	0,0239	0,0233
-1,8	0,0359	0,0351	0,0344	0,0336	0,0329	0,0322	0,0314	0,0307	0,0301	0,0294
-1,7	0,0446	0,0436	0,0427	0,0418	0,0409	0,0401	0,0392	0,0384	0,0375	0,0367
-1,6	0,0548	0,0537	0,0526	0,0516	0,0505	0,0495	0,0485	0,0475	0,0465	0,0455
-1,5	0,0668	0,0655	0,0643	0,063	0,0618	0,0606	0,0594	0,0582	0,0571	0,0559
-1,4	0,0808	0,0793	0,0778	0,0764	0,0749	0,0735	0,0721	0,0708	0,0694	0,0681
-1,3	0,0968	0,0951	0,0934	0,0918	0,0901	0,0885	0,0869	0,0853	0,0838	0,0823
-1,2	0,1151	0,1131	0,1112	0,1093	0,1075	0,1056	0,1038	0,102	0,1003	0,0985
-1,1	0,1357	0,1335	0,1314	0,1292	0,1271	0,1251	0,123	0,121	0,119	0,117
-1	0,1587	0,1562	0,1539	0,1515	0,1492	0,1469	0,1446	0,1423	0,1401	0,1379
-0,9	0,1841	0,1814	0,1788	0,1762	0,1736	0,1711	0,1685	0,166	0,1635	0,1611
-0,8	0,2119	0,209	0,2061	0,2033	0,2005	0,1977	0,1949	0,1922	0,1894	0,1867
-0,7	0,242	0,2389	0,2358	0,2327	0,2296	0,2266	0,2236	0,2206	0,2177	0,2148
-0,6	0,2743	0,2709	0,2676	0,2643	0,2611	0,2578	0,2546	0,2514	0,2483	0,2451
-0,5	0,3085	0,305	0,3015	0,2981	0,2946	0,2912	0,2877	0,2843	0,281	0,2776
-0,4	0,3446	0,3409	0,3372	0,3336	0,33	0,3264	0,3228	0,3192	0,3156	0,3121
-0,3	0,3821	0,3783	0,3745	0,3707	0,3669	0,3632	0,3594	0,3557	0,352	0,3483
-0,2	0,4207	0,4168	0,4129	0,409	0,4052	0,4013	0,3974	0,3936	0,3897	0,3859
-0,1	0,4602	0,4562	0,4522	0,4483	0,4443	0,4404	0,4364	0,4325	0,4286	0,4247
0	0,5	0,496	0,492	0,488	0,484	0,4801	0,4761	0,4721	0,4681	0,4641

z	0	0,5	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0,1	0,5398	0,5438	0,5478	0,5517	0,5557	0,5596	0,5636	0,5675	0,5714	0,5753	
0,2	0,5793	0,5832	0,5871	0,591	0,5948	0,5987	0,6026	0,6064	0,6103	0,6141	
0,3	0,6179	0,6217	0,6255	0,6293	0,6331	0,6366	0,6406	0,6443	0,648	0,6517	
0,4	0,6554	0,6591	0,6628	0,6664	0,67	0,6736	0,6772	0,6808	0,6844	0,6879	
0,5	0,6915	0,695	0,6985	0,7019	0,7054	0,7088	0,7123	0,7157	0,719	0,7224	
0,6	0,7257	0,7291	0,7324	0,7357	0,7389	0,7422	0,7454	0,7486	0,7517	0,7549	
0,7	0,758	0,7611	0,7642	0,7673	0,7704	0,7734	0,7764	0,7794	0,7823	0,7852	
0,8	0,7881	0,791	0,7939	0,7967	0,7995	0,8023	0,8051	0,8078	0,8106	0,8133	
0,9	0,8159	0,8186	0,8212	0,8238	0,8264	0,8288	0,8315	0,834	0,8365	0,8389	
1	0,8413	0,8438	0,8461	0,8485	0,8508	0,8531	0,8554	0,8577	0,8599	0,8621	
1,1	0,8643	0,8665	0,8686	0,8708	0,8729	0,8749	0,877	0,879	0,881	0,883	
1,2	0,8849	0,8869	0,8888	0,8907	0,8925	0,8944	0,8962	0,898	0,8997	0,9015	
1,3	0,9032	0,9049	0,9066	0,9082	0,9099	0,9115	0,9131	0,9147	0,9162	0,9177	
1,4	0,9192	0,9207	0,922	0,9236	0,9251	0,9265	0,9279	0,9292	0,9306	0,9319	
1,5	0,9332	0,9345	0,9357	0,937	0,9382	0,9394	0,9406	0,9418	0,9429	0,9441	
1,6	0,9452	0,9463	0,9474	0,9484	0,9495	0,9505	0,9515	0,9525	0,9535	0,9545	
1,7	0,9554	0,9564	0,9573	0,9582	0,9591	0,9599	0,9608	0,9616	0,9625	0,9633	
1,8	0,9641	0,9649	0,9656	0,9664	0,9671	0,9678	0,9686	0,9693	0,9699	0,9706	
1,9	0,9713	0,9719	0,9726	0,9732	0,9738	0,9744	0,975	0,9756	0,9761	0,9767	
2	0,9772	0,9778	0,9783	0,9788	0,9793	0,9798	0,9803	0,9808	0,9812	0,9817	
2,1	0,9821	0,9826	0,983	0,9834	0,9838	0,9842	0,9846	0,985	0,9854	0,9857	
2,2	0,9861	0,9864	0,9868	0,9871	0,9875	0,9878	0,9881	0,9884	0,9887	0,989	
2,3	0,9893	0,9896	0,9898	0,9901	0,9904	0,9906	0,9909	0,9911	0,9913	0,9916	
2,4	0,9918	0,992	0,9922	0,9925	0,9927	0,9929	0,9931	0,9932	0,9934	0,9936	
2,5	0,9938	0,994	0,9941	0,9943	0,9945	0,9946	0,9948	0,9949	0,9951	0,9952	
2,6	0,9953	0,9955	0,9956	0,9957	0,9959	0,996	0,9961	0,9962	0,9963	0,9964	
2,7	0,9965	0,9966	0,9967	0,9968	0,9969	0,997	0,9971	0,9972	0,9973	0,9974	
2,8	0,9974	0,9975	0,9976	0,9977	0,9977	0,9978	0,9979	0,9979	0,998	0,9981	
2,9	0,9981	0,9982	0,9982	0,9983	0,9984	0,9984	0,9985	0,9985	0,9986	0,9986	
3	0,9987	0,9987	0,9987	0,9988	0,9988	0,9989	0,9989	0,9989	0,999	0,999	
3,1	0,999	0,9991	0,9991	0,9991	0,9992	0,9992	0,9992	0,9992	0,9993	0,9993	
3,2	0,9993	0,9993	0,9994	0,9994	0,9994	0,9994	0,9994	0,9994	0,9995	0,9995	
3,3	0,9995	0,9995	0,9995	0,9996	0,9996	0,9996	0,9996	0,9996	0,9996	0,9996	
3,4	0,9997	0,9997	0,9997	0,9997	0,9997	0,9997	0,9997	0,9997	0,9997	0,9997	

Analisi dei dati

Outlier

Criterio di Chauvenet

Esempio: Supponiamo di aver fatto 8 misure della grandezza X:

1	2	3	4	5	6	7	8
14.1	13.4	13.8	13.0	11.8	14.1	13.0	14.0

1) Calcoliamo $\bar{x} = \frac{1}{8} \sum_{i=1}^8 x_i = 13.4$ e $\sigma = \sqrt{\frac{1}{7} \sum_{i=1}^8 (x_i - \bar{x})^2} = 0.8$ e lo scarto normale:

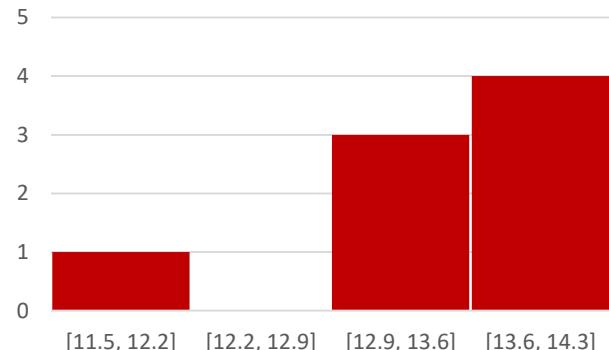
1	2	3	4	5	6	7	8
0.88	0.00	0.51	-0.51	-2.02	0.88	-0.51	0.76

2) $p_C = 1 - \frac{1}{2n} = 1 - \frac{1}{16} = 0.94$

3) $F(z_{lim}) = \frac{p_C+1}{2} = 0.97$

4) $z_{lim} = 1.86$

5) Si scarta il dato $|x_5| > z_{lim}$



Analisi dei dati

Outlier

Criterio di Chauvenet

Esempio: Riprendiamo le misure di pressione precedenti.

4.35 4.46 4.39 4.34 4.41 4.52 4.44 4.37 4.41 4.33 4.39 4.47 4.42 4.59 4.45 4.38 4.43 4.36 4.48 4.45

1) Calcoliamo $\bar{x} = \frac{1}{20} \sum_{i=1}^{20} x_i = 4.42$ e $\sigma = \sqrt{\frac{1}{19} \sum_{i=1}^{20} (x_i - \bar{x})^2} = 0.06$ e lo scarto normale:

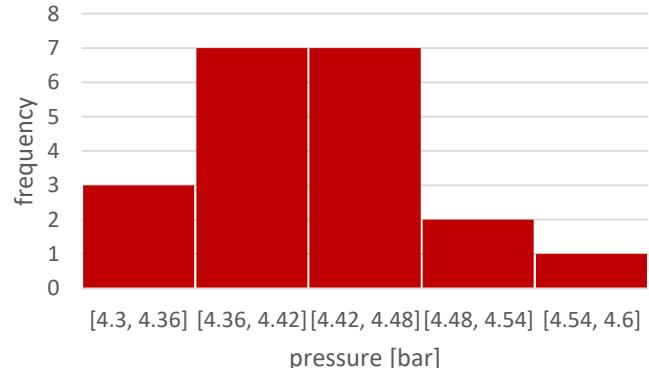
-1.12 0.59 -0.50 -1.28 -0.19 1.53 0.28 -0.81 -0.19 -1.44 -0.50 0.75 -0.03 2.62 0.44 -0.66 0.12 -0.97 0.91 0.44

2) $p_C = 1 - \frac{1}{2n} = 1 - \frac{1}{40} = 0.975$

3) $F(z_{lim}) = \frac{p_C+1}{2} = 0.9875$

4) $z_{lim} = 2.24$

5) Si **scarta** il dato $|2.62| > z_{lim}$, quindi 4.59



Analisi dei dati

Come riassumere i dati

Media del campione, mediana del campione e moda del campione

Esempio:

La lunghezza di una barra d'acciaio viene misurata in millimetri da diversi osservatori (11 misure).

Measurement set A

398	420	394	416	404	408	400	420	396	413	430
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

Le misure sono fatte nuovamente usando una procedura di misura migliore e con gli osservatori che fanno più attenzione.

Measurement set B

409	406	402	407	405	404	407	404	407	407	408
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

Aumentiamo il numero di misurazioni estendendo il set di misurazioni B a 23 misurazioni.

Measurement set C

409	406	402	407	405	404	407	404	407	407	408	406	410	406	405	408	406	409	406	405	409	406	407
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

Analisi dei dati

Come riassumere i dati

Media del campione, mediana del campione e moda del campione

Measurement set A

$$x_{mean} = 409.0$$

$$x_{median} = 408$$

$$x_{mode} = 420$$

Measurement set B

$$x_{mean} = 406.0$$

$$x_{median} = 407$$

$$x_{mode} = 407$$

Measurement set C

$$x_{mean} = 406.5$$

$$x_{median} = 406$$

$$x_{mode} = 406$$

Analisi dei dati

Come riassumere i dati

Varianza e deviazione standard del campione

deviazione (errore) $d_i = x_i - x_{mean}$

$$\sigma^2 = \frac{d_1^2 + d_2^2 + \cdots + d_n^2}{n}$$

$$\sigma = \sqrt{\sigma^2} = \sqrt{\frac{d_1^2 + d_2^2 + \cdots + d_n^2}{n}}$$

Le definizioni formali per la varianza e la deviazione standard dei dati sono fatte rispetto a una popolazione infinita di valori di dati, mentre in tutte le situazioni pratiche, possiamo avere solo un insieme finito di misure.

Analisi dei dati

Come riassumere i dati

Varianza e deviazione standard del campione

Una migliore previsione della varianza della popolazione infinita può essere ottenuta applicando il fattore di correzione di Bessel $\frac{n}{n-1}$:

$$s^2 = \frac{n}{n-1} \sigma^2 = \frac{d_1^2 + d_2^2 + \dots + d_n^2}{n-1}$$
$$s = \sqrt{s^2} = \sqrt{\frac{d_1^2 + d_2^2 + \dots + d_n^2}{n-1}}$$

s^2 è la varianza dell'insieme finito di misure e σ^2 è la varianza della popolazione infinita di misure.

Analisi dei dati

Come riassumere i dati

Varianza e deviazione standard del campione

Esempio:

Set A	Measurement	Deviation	(Deviations) ²
1	398	-11.0	121
1	420	11.0	121
1	394	-15.0	225
1	416	7.0	49
1	404	-5.0	25
1	408	-1.0	1
1	400	-9.0	81
1	420	11.0	121
1	396	-13.0	169
1	413	4.0	16
1	430	21.0	441
Sum	11	4499	0
			1370

Mean	variance	standard deviation
409.0	137.0	11.7

Analisi dei dati

Come riassumere i dati

Varianza e deviazione standard del campione

Set B		Measurement	Deviation	(Deviations) ²
	1	409	3.0	9
	1	406	0.0	0
	1	402	-4.0	16
	1	407	1.0	1
	1	405	-1.0	1
	1	404	-2.0	4
	1	407	1.0	1
	1	404	-2.0	4
	1	407	1.0	1
	1	407	1.0	1
	1	408	2.0	4
Sum	11	4466	0	42

Mean	variance	standard deviation
406.0	4.20	2.05

Analisi dei dati

Come riassumere i dati

Varianza e deviazione standard del campione

Set C		Measurement	Deviation	(Deviations) ²
	1	409	2.5	6.4
	1	406	-0.5	0.2
	1	402	-4.5	20.1
	1	407	0.5	0.3
	1	405	-1.5	2.2
	1	404	-2.5	6.1
	1	407	0.5	0.3
	1	404	-2.5	6.1
	1	407	0.5	0.3
	1	407	0.5	0.3
	1	408	1.5	2.3
	1	406	-0.5	0.2
	1	410	3.5	12.4
	1	406	-0.5	0.2
	1	405	-1.5	2.2
	1	408	1.5	2.3
	1	406	-0.5	0.2
	1	409	2.5	6.4
	1	406	-0.5	0.2
	1	405	-1.5	2.2
	1	409	2.5	6.4
	1	406	-0.5	0.2
Sum	23	9349	6.25E-13	77.7

mean	variance	standard deviation
406.5	3.53	1.88

Analisi dei dati

Come riassumere i dati

Percentili del campione e box plot

Definizione

Il $100p$ percentile del campione è quel valore di dati tale che il $100p$ per cento dei dati è inferiore o uguale ad esso e il $100(1-p)$ per cento è maggiore o uguale ad esso. Se due valori di dati soddisfano questa condizione, allora il $100p$ percentile del campione è la media aritmetica di questi due valori.

Per determinare il $100p$ percentile del campione di un insieme di dati di dimensioni n , dobbiamo determinare i valori dei dati tali che

1. Almeno np dei valori siano inferiori o uguali ad esso.
2. Almeno $n(1-p)$ dei valori siano maggiori o uguali ad esso.

Analisi dei dati

Come riassumere i dati

Percentili del campione e box plot

Definizione

Il 25° percentile del campione è chiamato **primo quartile**; il 50° percentile del campione è chiamato mediana del campione o **secondo quartile**; il 75° percentile del campione è chiamato **terzo quartile**.

I quartili dividono una serie di dati in quattro parti, con il 25% dei dati che sono inferiori al primo quartile, il 25% tra il primo e il secondo quartile, il 25% tra il secondo e il terzo quartile e il 25% superiore al terzo quartile.

Analisi dei dati

Come riassumere i dati

Percentili del campione e box plot

Starting salary	Frequency
47	4
48	1
49	3
50	5
51	8
52	10
53	0
54	5
56	2
57	3
60	1

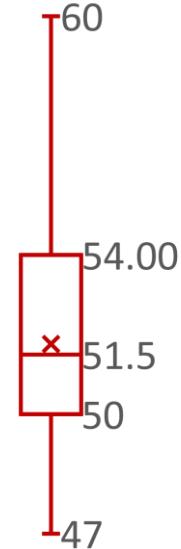
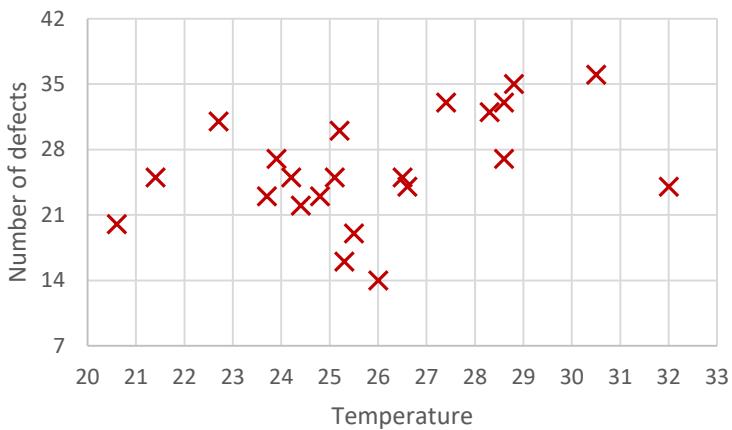


Diagramma a scatola e baffi o diagramma degli estremi e dei quartili o box and whiskers plot o box-plot.

Analisi dei dati

Serie di dati appaiati e coefficiente di correlazione

Esempio: nel tentativo di determinare la relazione tra la temperatura giornaliera di mezzogiorno (misurata in gradi Celsius) e il numero di pezzi difettosi prodotti durante quel giorno, un'azienda ha registrato i dati presentati nella tabella. Per questa serie di dati, x_i rappresenta la temperatura in gradi Celsius e y_i il numero di pezzi difettosi prodotti il giorno i .



Day	Temperature	Number of defects
1	24.2	25
2	22.7	31
3	30.5	36
4	28.6	33
5	25.5	19
6	32.0	24
7	28.6	27
8	26.5	25
9	25.3	16
10	26.0	14
11	24.4	22
12	24.8	23
13	20.6	20
14	25.1	25
15	21.4	25
16	23.7	23
17	23.9	27
18	25.2	30
19	27.4	33
20	28.3	32
21	28.8	35
22	26.6	24

Analisi dei dati

Serie di dati appaiati e coefficiente di correlazione

Supponiamo che l'insieme di dati sia costituito da valori appaiati $(x_i, y_i), i = 1, \dots n$.

Definizione

Lasciamo che \bar{x} e \bar{y} denotino le medie campionarie dei valori x e dei valori y , rispettivamente e s_x e s_y denotino, rispettivamente, le deviazioni standard del campione dei valori x e dei valori y . Il **coefficiente di correlazione campionaria**, detto r , delle coppie di dati $(x_i, y_i), i = 1, \dots n$ è definito da

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

Quando $r > 0$ diciamo che i dati del campione sono **correlati positivamente** e quando $r < 0$ diciamo che i dati del campione sono **correlati negativamente**.

Analisi dei dati

Serie di dati appaiati e coefficiente di correlazione

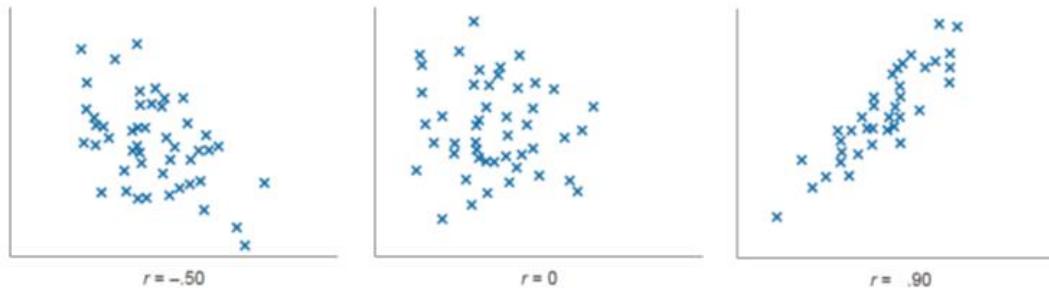
Proprietà di r

- $-1 \leq r \leq 1$
- Se per costanti a e b , con $b > 0$
 $y_i = a + bx_i, i = 1, \dots n$
allora $r = 1$.
- Se per le costanti a e b , con $b < 0$
 $y_i = a + bx_i, i = 1, \dots n$
allora $r = -1$.
- Se r è il coefficiente di correlazione campionaria per le coppie di dati $x_i, y_i, i = 1, \dots n$ allora esso è anche il coefficiente di correlazione campionaria per le coppie di dati
 $a + bx_i, c + dy_i, i = 1, \dots n$
a condizione che b e d siano entrambi positivi o entrambi negativi.

Analisi dei dati

Serie di dati appaiati e coefficiente di correlazione

La figura mostra i diagrammi di dispersione per serie di dati con vari valori di r .





UNIVERSITÀ
DEGLI STUDI
DI TRIESTE



Dipartimento di
**Ingegneria
e Architettura**