

---

# METODI STATISTICI E COMPUTAZIONALI

---

Stefania Spagnolo

*Dipartimento di Matematica e Fisica, Univ. del Salento*



---

# ANALISI DATI

---

---

# LEZIONE 5

---

# ANALISI DATI

## Tipologie di Osservabili

### Quantitative (hard)

- Si può associare un valore numerico ed unità di misura
- Es.: La temperatura dell'acqua in K. Le osservabili quantitative sono la base della scienza galileiana e delle cosiddette "hard sciences": le discipline basate su osservabili rigorose connesse tra loro da modelli matematici.

### Qualitative (soft)

- Etichette, descrittori, categorie
- Generalmente sono espresse verbalmente ("Il corpo è sferico, il soggetto ha un carattere irritabile").
- Osservabili difficilmente standardizzabili e/o riproducibili (es. analisi sensoriale)
- Fuzzy logics: tentativo di rendere quantitative delle osservabili espresse verbalmente

# ANALISI DATI

## Tipologie di Osservabili

### Osservabili **discrete**

Sono associati a processi che possono assumere solo un insieme limitato di valori predefiniti (es. facce di un dado, stato di spin di una particella)

### Osservabili **continue**

Sono associati a processi che possono dare origine a un insieme continuo di valori possibili. Tali valori possono essere limitati o illimitati (es. temperatura di un liquido, velocità di una particella)

***I limiti strumentali possono dar luogo a discretizzazioni***

Esempio conversione Analogico-Digitale

# ANALISI DATI

## In termini statistici

- Un *insieme S contenente tutti i possibili risultati di un esperimento* è detto **spazio campione** e ciascun risultato è detto elemento o punto di S. **Un evento (A) in S è costituito da 1 o più elementi di S. L'insieme di tutti gli eventi in S è anche detto campo di Borel**
- Uno spazio campione può essere finito o infinito, continuo o discreto.
  - es.: lancio di un dado => spazio discreto finito
  - serie storica a lotto => spazio discreto infinito
  - misura di una lunghezza => spazio continuo
- La **variabile aleatoria** mi permette di associare ad un evento dello spazio di Borel un **valore numerico**.
  - Esempi: La temperatura dell'acqua è 400 K; Indico con 1 i corpi sferici.

$$X : \mathbf{B} \rightarrow \mathfrak{R}$$

- Variabili **aleatorie discrete e continue finite o infinite**

$$X(w_i) = x_i \quad w_i \in \mathbf{B}, x_i \in \mathfrak{R}$$

# ANALISI DATI

## In termini statistici

- Per indicare il valore assunto dalla variabile aleatoria che identifica il risultato numerico di un esperimento si usa il termine ***dato*** o ***misura***.
- Per misure sperimentali occorre ricordare che:
  - Esiste sempre una ***calibrazione*** che lega il dato al valore dell'osservabile. Lo strumento, qualunque esso sia, è calibrato per effettuare la misura.
  - La tecnica di misura usata può non essere selettiva. Una misura si dice ***selettiva*** se esiste una ***corrispondenza biunivoca tra ingresso dello strumento e risultato della misura***.
  - ***L'osservabile può avere una sua legge e/o una sua distribuzione di probabilità***. In questo caso è possibile solo l'estrazione di un campione e la valutazione delle proprietà della distribuzione di probabilità che è responsabile del processo.
  - ***Il dato è soggetto a processi stocastici*** legati alla tecnica utilizzata nell'esperimento, al tipo di strumenti usati e all'operato degli sperimentatori. La misura è caratterizzata da un valore e da un errore.

# ANALISI DATI

## Calibrazione

- Quasi sempre la singola misura è il risultato di un'azione che richiede l'utilizzo di uno o più strumenti di misura.
- Gli strumenti di misura danno una risposta che è legata all'osservabile che si vuole valutare attraverso una calibrazione

Es.: Misura di una temperatura con un termometro ad alcool.

- Osservabile (T): temperatura
- Risposta strumento (L): dilatazione lineare su scala graduata

$$L = k \cdot T$$

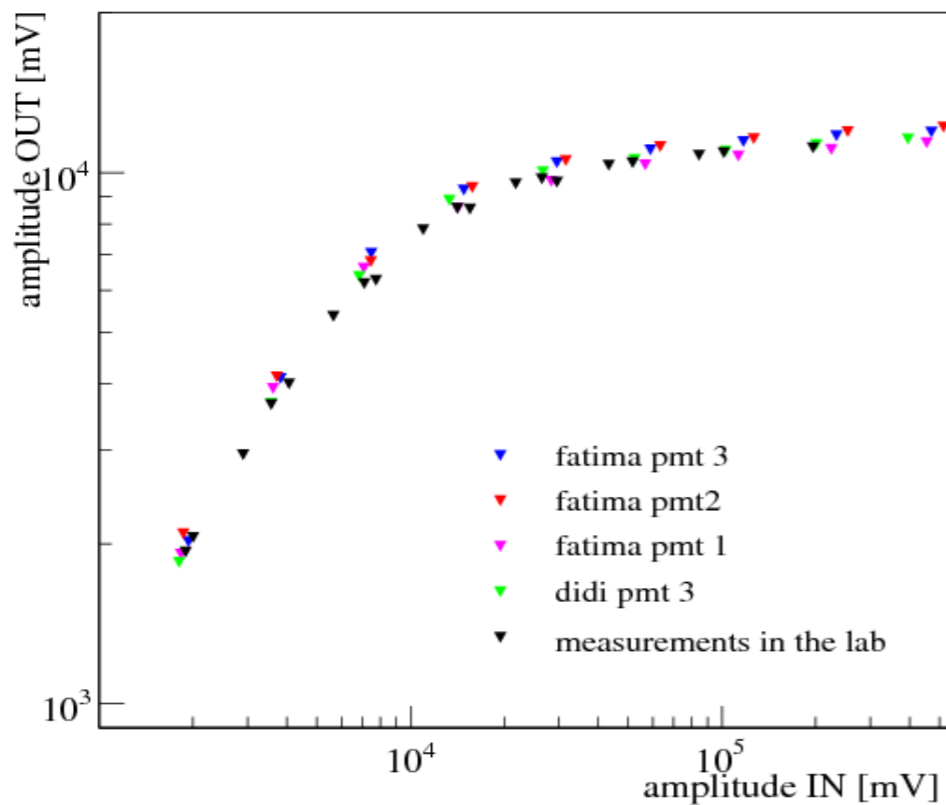
k costante di calibrazione

Questo è un esempio di variabile aleatoria **selettiva** associata ad un osservabile.  
La calibrazione è **lineare**.

- Non sempre, però, si è in queste condizioni. Si possono avere funzioni di calibrazione non lineari e/o variabili aleatorie non selettive.



# ANALISI DATI



## Misura selettiva e non selettiva


Curva di risposta di un fotomoltiplicatore.

Misura **selettiva**:

- ad ogni tensione di ingresso corrisponde una e una sola ampiezza del segnale in tensione di uscita.
- sono chiaramente distinguibili una regione di linearità (sino a circa 4-5 V) e una regione di non linearità.

La funzione di **calibrazione è non lineare**.

L'errore associato alla misura non è costante.



Equazione dei gas perfetti.

Per determinare lo stato del gas occorre misurare due grandezze. La sola misura della pressione non mi permette di determinare il volume. **P non è una misura selettiva** di V.

$$P = \frac{nRT}{V}$$

# ANALISI DATI

## Errore di Misura

- **Il risultato di una misura è una variabile aleatoria** in quanto al **processo di misura** sono associate fluttuazioni dovuta a varie cause che rendono la misura non esattamente riproducibile. La misura è riproducibile sono in termini statistici.

$$Y = k \cdot X + \varepsilon$$

- $Y$  risposta dello strumento,  $X$  osservabile da misurare,  $\varepsilon$  errore della misura. Tipicamente si assume che gli errori statistici fluttuino in maniera gaussiana


## Teorema del Limite Centrale

"se si ha una somma di variabili aleatorie indipendenti e identicamente distribuite con media  $\mu$  e varianza  $\sigma^2$ , allora indipendentemente dalla forma distributiva di partenza, al tendere della dimensione campionaria a infinito la somma tende a distribuirsi come una variabile casuale normale"

# ANALISI DATI

## Processi fisici stocastici

- L'**osservabile** che si vuole valutare può essere a sua volta frutto di un processo stocastico con una sua distribuzione di probabilità.
- Esempio
  - una particella carica che attraversa un sottile strato di materia rilascia nel mezzo una frazione della sua energia. Il processo alla base di questo fenomeno è un processo stocastico. **La distribuzione di probabilità** dell'energia ceduta al mezzo è una distribuzione di **Landau**.
  - Supponiamo di voler misurare questa perdita attraverso un rivelatore che mi produce una d.d.p. direttamente proporzionale alla quantità di energia rilasciata.



$$\Delta V = k \cdot \Delta E + \varepsilon$$

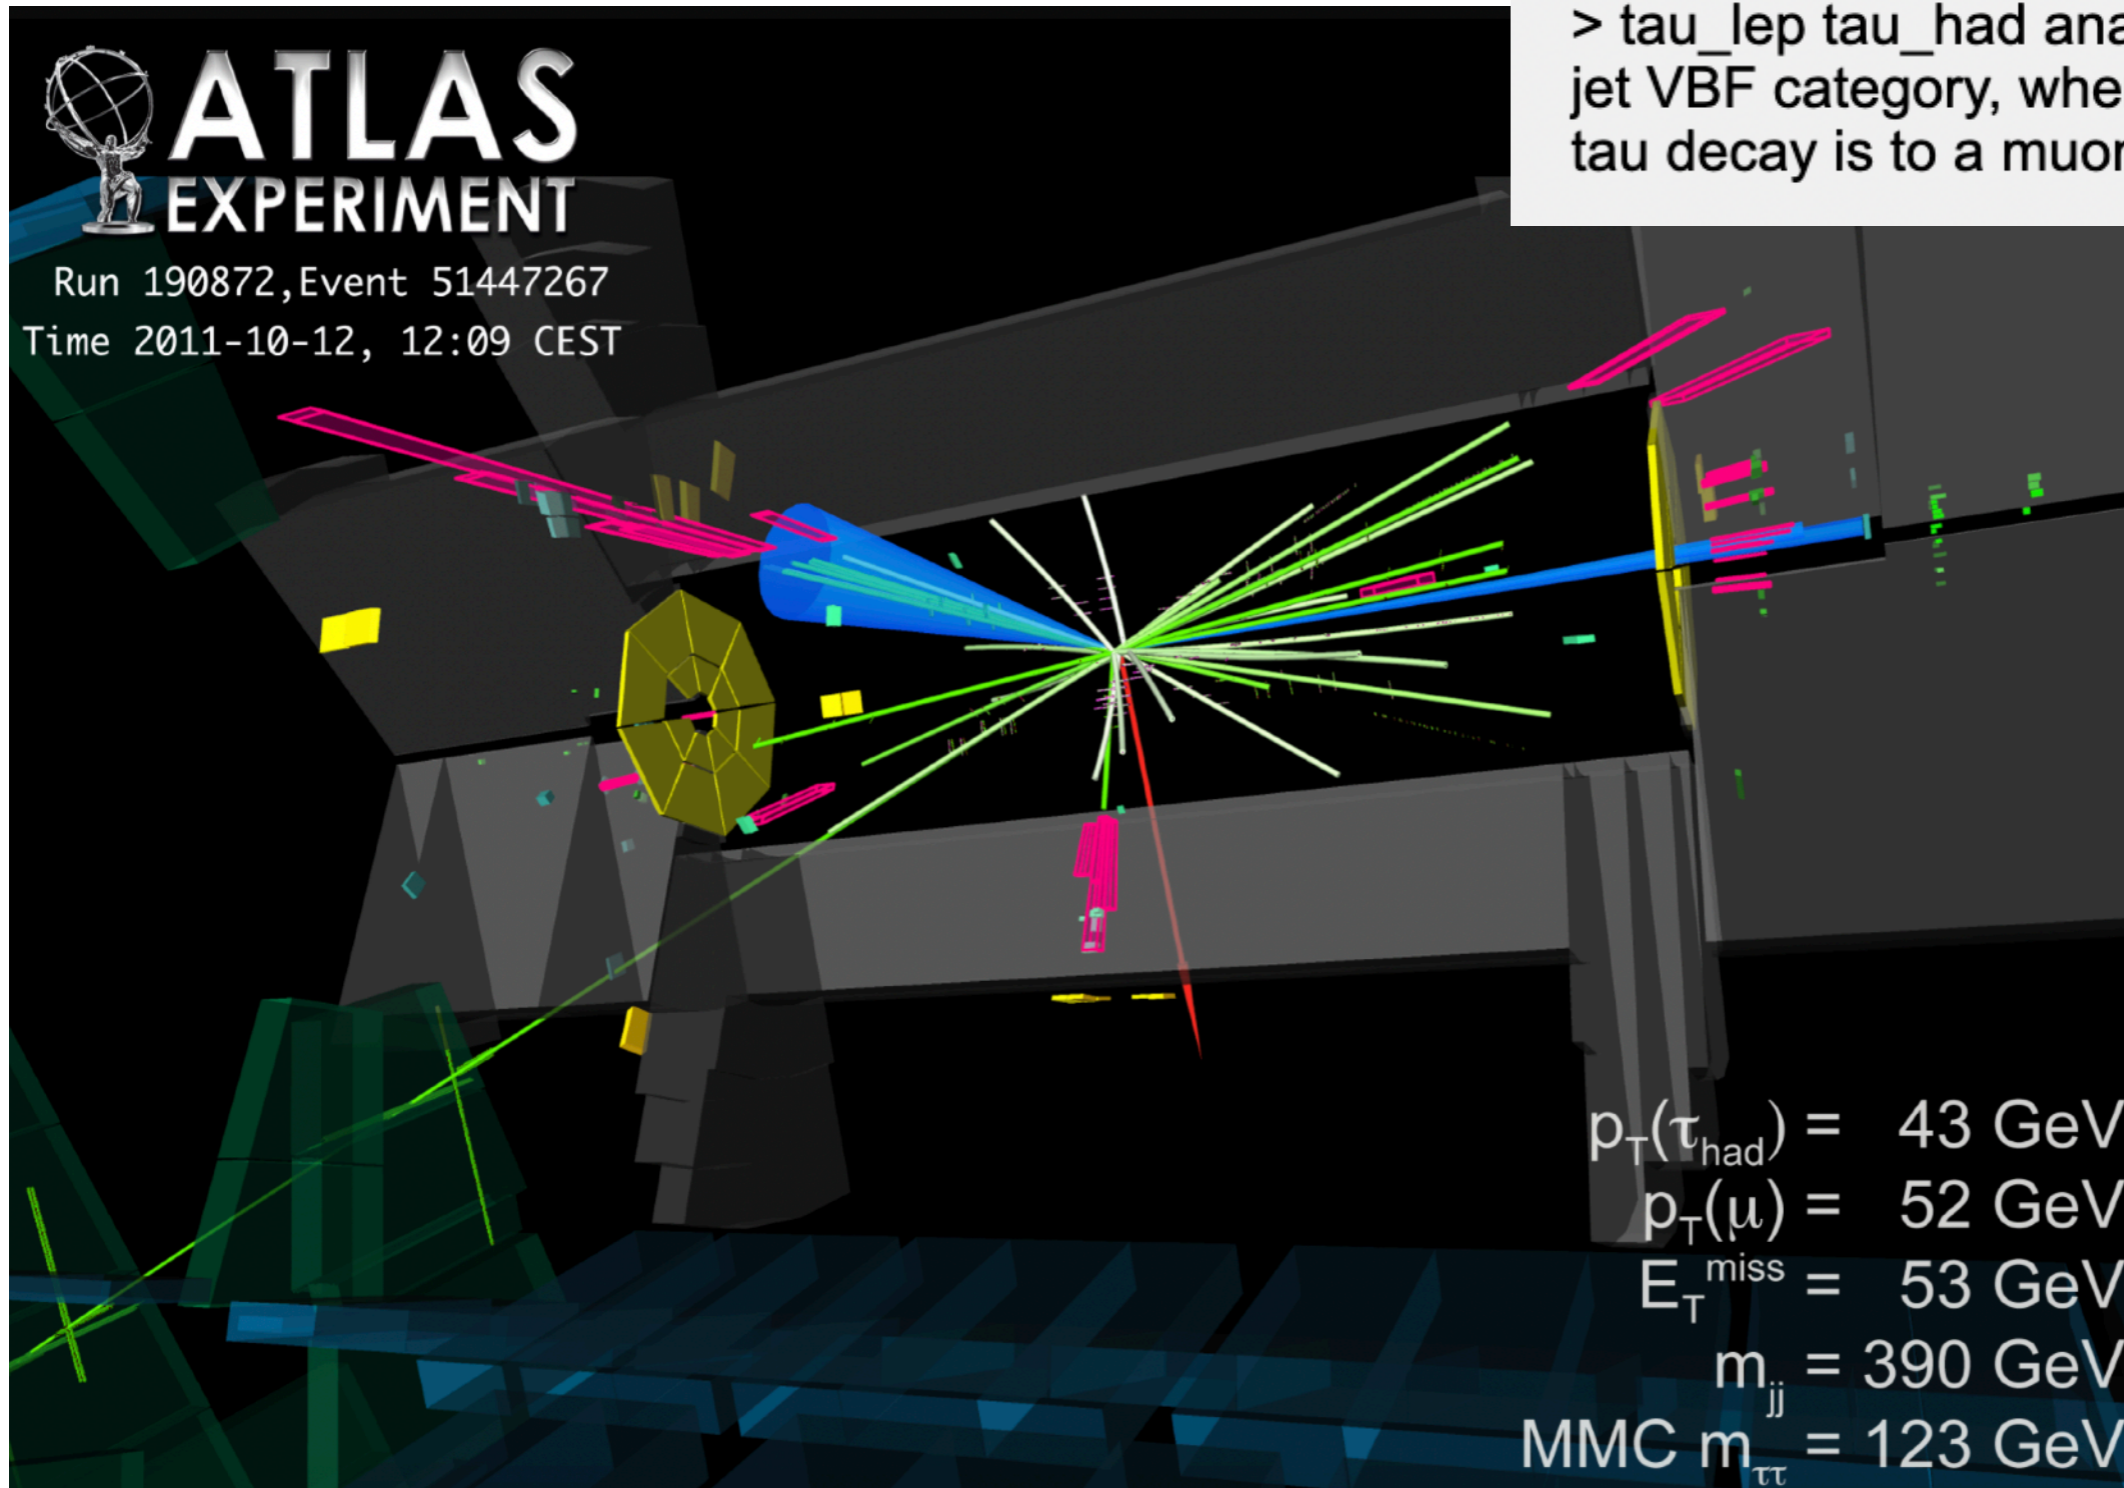
$\Delta E$  Segue una distribuzione di Landau

$\varepsilon$  Segue una distribuzione di Gauss

# ANALISI DATI

- Molti procedimenti sperimentali tendono a produrre **dati univariati** in cui cioè il dato sperimentale dipende da una sola grandezza
  - Misura di una singola grandezza incognita
- Anche in questo caso “semplice” la determinazione del risultato richiede una serie di accortezze:
  - Attenzione alle possibili interferenze con la misura
  - Mantenere costanti le condizioni in cui la misura è eseguita
  - Preparare accuratamente l’esperimento per isolare la grandezza da misurare
- Nonostante ciò, molti fenomeni sono intrinsecamente complessi e modellabili solo considerando una molteplicità di indicatori
- Alcuni apparati sperimentali producono una grande quantità di dati evento


# ANALISI DATI



Display of an event selected by the H -> tau\_lep tau\_had analysis in the H+2-jet VBF category, where the leptonic tau decay is to a muon. (*figaux\_17*)

# ANALISI DATI

- Col termine **analisi multivariata** si indica quell'insieme di metodi statistici usati per analizzare simultaneamente piu' caratteri.
- In tutte le analisi statistiche multivariate il materiale grezzo e' costituito da **un certo numero di eventi (osservazioni) che si vogliono studiare simultaneamente.**



# ANALISI DATI

- Col termine **analisi multivariata** si indica quell'insieme di metodi statistici usati per analizzare simultaneamente piu' caratteri.
- In tutte le analisi statistiche multivariate il materiale grezzo e' costituito da un certo numero di **eventi** (osservazioni) che si vogliono studiare simultaneamente.
- In altri casi si cercano correlazioni relazioni funzionali tra gruppi di variabili (**regressione**)
- In altri casi ancora si può essere interessati a ridurre le dimensioni della variabile multipla considerata (identificazione delle **componenti principali**).
- In alcuni casi l'obiettivo dell'analisi e' semplicemente quello di classificare gli eventi sulla base di tutte le variabili considerate (**classificazione**).
- L'analisi multivariata è comunemente usata in fisica e inconsciamente ne avete già fatto uso. La regressione è un esempio di analisi multivariata.

# ANALISI DATI

- Le precedenti osservazioni hanno evidenziato il legame che esiste tra il concetto di *misura* e la *statistica*.
- L'aleatorietà del processo di misura dovuta alla presenza di un errore di misura rende indispensabile lo studio della statistica.
- Nel corso delle prossime lezioni affronteremo rapidamente nell'ordine:
  - **Il concetto di probabilità nelle sue varie formulazioni**
  - **Le variabili aleatorie** come grandezze in grado di quantificare un evento casuale
  - **La teoria dei campioni** e il suo legame con il processo di misura.
- Durante tutto il corso faremo spesso ricorso a simulazione di processi mediante tecniche Monte Carlo per mettere in pratica o "sperimentare" quanto visto in teoria.
- Affronteremo, infine, tecniche di analisi dati più specifiche e metodi numerici utili per risolvere problemi fisici.



---

# RICHIAMI DI CALCOLO COMBINATORIO E PROBABILITÀ

---

# CALCOLO COMBINATORIO E PROBABILITÀ

- **Un insieme  $S$  contenente tutti i possibili risultati di un esperimento è detto spazio campione** e ciascun risultato è detto elemento o punto di  $S$ .
- Un **evento ( $A$ ) in  $S$**  è costituito da 1 o più elementi di  $S$ . **L'insieme di tutti gli eventi in  $S$  è anche detto campo di Borel**
- Uno spazio campione può essere finito o infinito, continuo o discreto
- Esempi:
  - lancio di un dado == spazio discreto finito
  - serie storica a lotto == spazio discreto infinito
  - misura di una lunghezza == spazio continuo
- Esiste un evidente parallelismo tra l'**algebra degli eventi** e quella degli **insiemi**

Unione	$A \cup B$	evento A oppure B
Intersezione	$A \cap B$	sia l'evento A che quello B
Complementare	$\bar{A}$	l'evento non A
Differenza	$A - B$	l'evento A ma non B

# CALCOLO COMBINATORIO E PROBABILITÀ

- Sommario

Proprietà delle operazioni insiemistiche:

$$A \cup B = B \cup A \quad A \cap B = B \cap A \quad \text{Proprietà commutativa}$$

$$A \cup (B \cup C) = (A \cup B) \cup C \quad A \cap (B \cap C) = (A \cap B) \cap C \quad \text{associativa}$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

Proprietà distributiva

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$


$$\overline{A \cap B} = \overline{A} \cup \overline{B}$$

Legge di De Morgan

$$\overline{A \cup B} = \overline{A} \cap \overline{B}$$

Legge di De Morgan

# CALCOLO COMBINATORIO E PROBABILITÀ

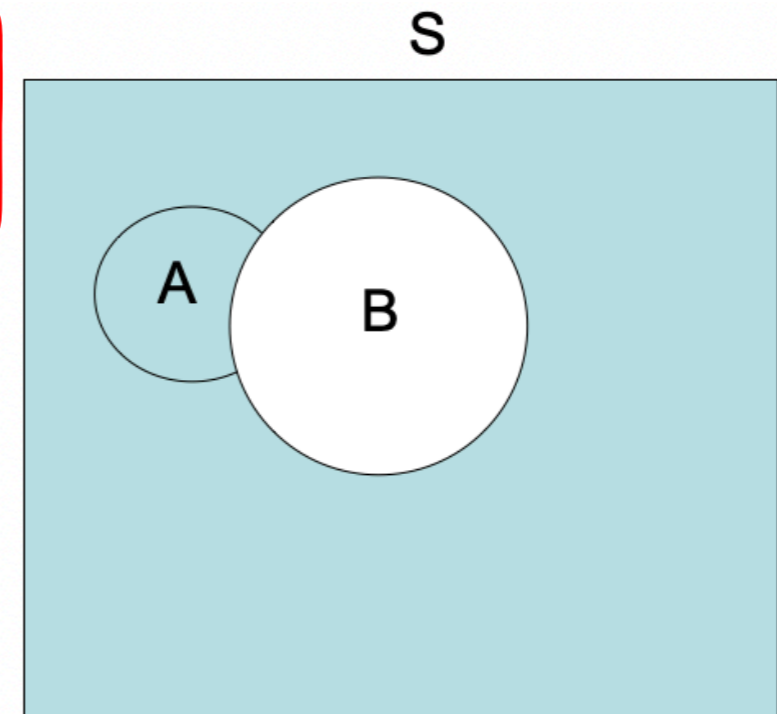


Area azzurra  $\overline{A \cap B}$


Legge di De Morgan

$$\overline{A \cap B}$$

S



Area azzurra  $\overline{A}$



Area azzurra  $\overline{B}$

$$\overline{A} \cup \overline{B} = \overline{A \cap B}$$

- Dimostrazione grafica della Legge di De Morgan

# CALCOLO COMBINATORIO E PROBABILITÀ

- **Disposizioni**, di  $n$  **oggetti** in **gruppi di  $k$** , con ripetizioni
  - Conta l'ordine, possibili le ripetizioni
    - Gli  $n$  oggetti possono tutti essere usati a ognuna delle  $k$  estrazioni

$$n^k$$

- **Disposizioni**, di  $n$  **oggetti** in **gruppi di  $k$** , semplici **senza ripetizioni**
  - Conta l'ordine, non si possono avere ripetizioni
    - Alla prima delle  $k$  estrazioni ho  $n$  possibilità, alla seconda  $n-1$ , alla  $k$ -esima  $n-k+1$
    - **NOTA:**
      - Disposizioni, di  $n$  **oggetti** in **gruppi di  $n$** , (**permutazioni**)  **$n!$**

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


- **Combinazioni**, di  $n$  **oggetti** in **gruppi di  $k$** ,
  - Non conta l'ordine e non si possono avere ripetizione; il numero di combinazioni = numero di disposizioni / permutazioni di  $k$  oggetti

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

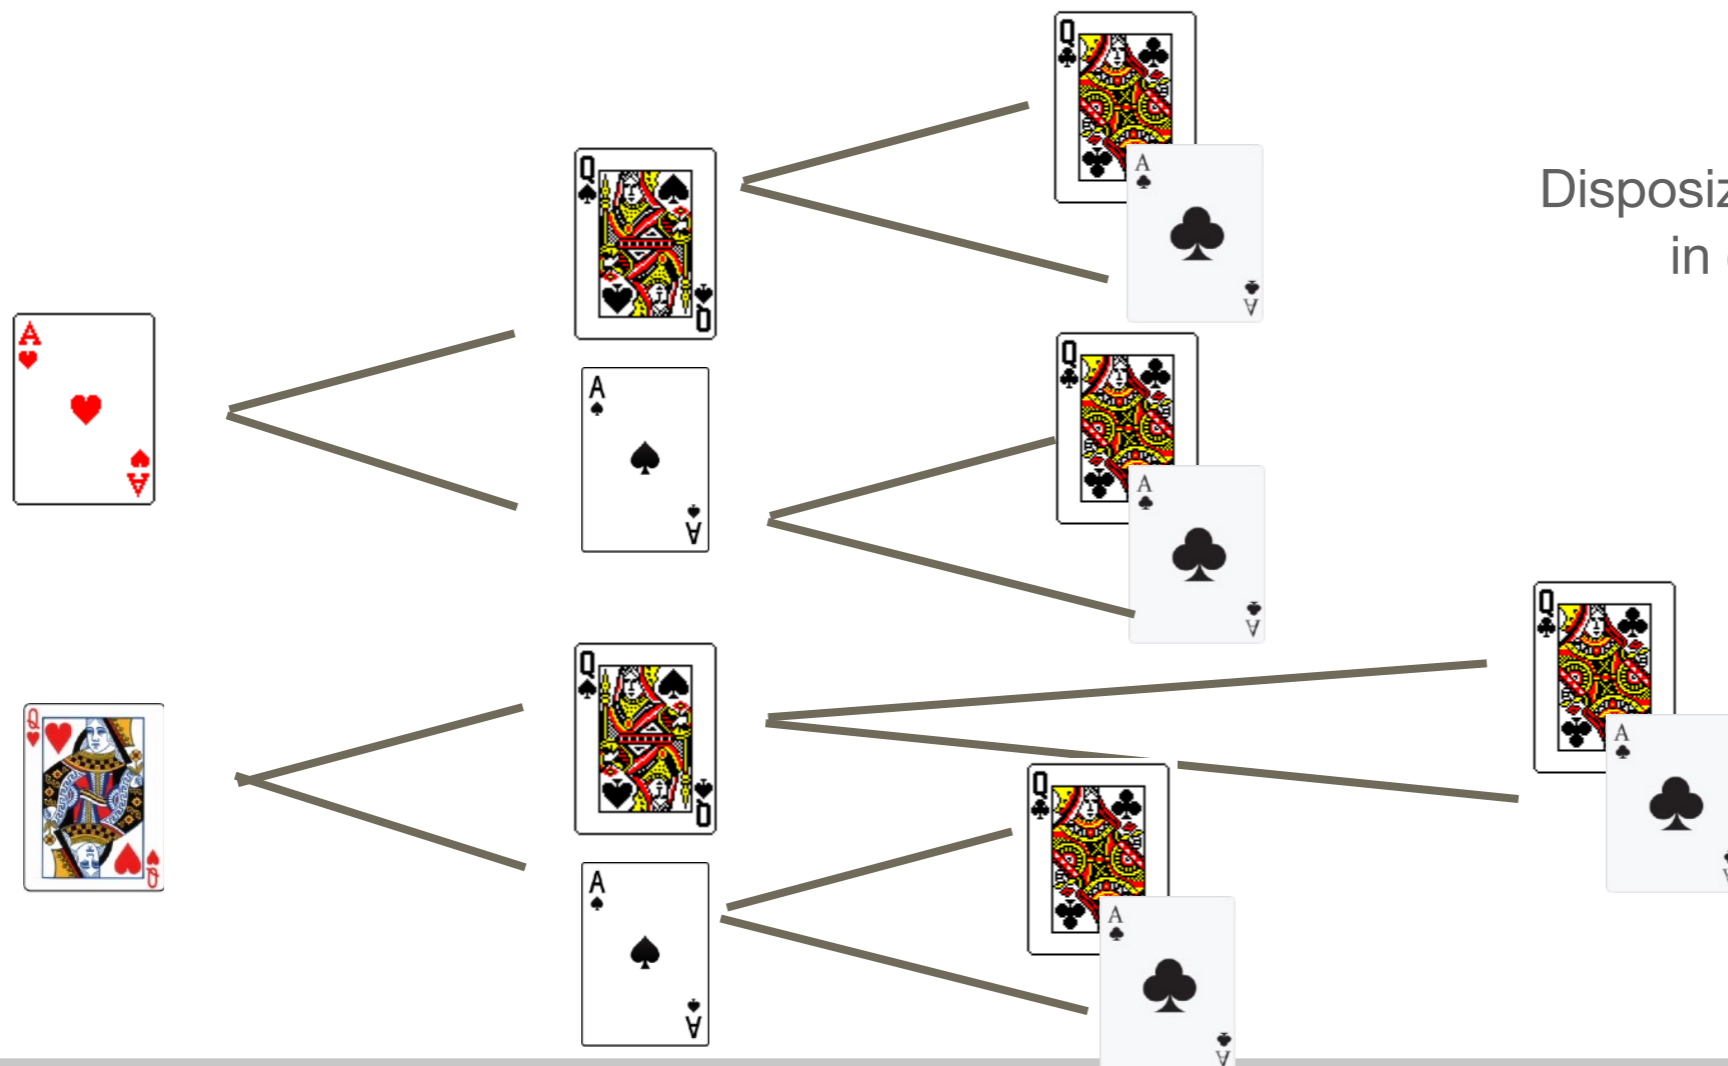
# CALCOLO COMBINATORIO E PROBABILITÀ

Ho a disposizione 2 carte di cuori, due di picche e 2 di fiori

■ **Disposizioni**



Ne scelgo una di ogni seme, quante possibilità ho ?  
=> **Disposizioni**



Disposizioni di  $n=2$  (2 carte /seme)  
in gruppi di  $k=3$  (3 semi)

$$2 \times 2 \times 2 = 2^3$$

# CALCOLO COMBINATORIO E PROBABILITÀ

## ■ Disposizioni

Ho a disposizione 10 cifre, da 0 a 9

Quanti numeri di 4 cifre posso formare

=> **Disposizioni**

Le disposizioni sono ammesse  
ovviamente

$$10 \times 10 \times 10 \times 10 = 10^4$$

0000

0001

0002

...

1027

1028

1029

1030

1031

...

9997

9998

9999

# CALCOLO COMBINATORIO E PROBABILITÀ

## ■ Disposizioni semplici senza ripetizioni

Quante possibili terne ordinate si possono formare estraendo 3 numeri dal bussolotto del lotto?

1-2-3, 1-2-4, 1-2-5, ....., 90-89-88

Per il primo numero posso scegliere tra 90,  
per il secondo solo tra 89  
per il terzo tra 88

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

$90 \cdot (90-1) \cdot (90-2)$

In generale  $n(n-1)(n-2) \dots (n-k+1)$

## ■ Combinazioni

Se per le terne non conta l'ordine di estrazione, *siccome ogni terna può comparire in 3! permutazioni*,  
cioè 1-2-3, 1-3-2, 2-3-1, ecc sono equivalenti

$90 \cdot (90-1) \cdot (90-2) / 3!$

In generale:

$n(n-1)(n-2) \dots (n-k+1) / k!$

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

## Coefficienti binomiali



# CALCOLO COMBINATORIO E PROBABILITÀ

- Giocando a Poker, ho in mano una coppia di donne e un asso.
- E' più conveniente chiedere tre carte scartando l'asso (caso A) o chiederne solo due e tenersi l'asso (caso B) ?



Identifichiamo lo **spazio campione**

32 carte nel mazzo, 5 carte mie -> 27 possibili valori delle carte a disposizione



Caso A

$$\frac{27!}{3! (27 - 3)!} = 27 \times 26 \times 25 / (3 \times 2) = 2925$$

Caso B

$$\frac{27!}{2! (27 - 2)!} = 27 \times 26 / 2 = 351$$

# CALCOLO COMBINATORIO E PROBABILITÀ

- Per rispondere alla domanda se è più “conveniente” tenersi l’asso o no, occorre introdurre il **concetto di probabilità**.
  - Una scelta è più conveniente dell’altra se rende più probabile il successo.

## Definizione di probabilità:

### 1. Probabilità matematica o a priori

Si basa sul concetto di “eventi ugualmente probabili”

### 2. Probabilità frequentistica o a posteriori

Necessità di definire un “n molto grande”

### 3. Probabilità soggettiva

Non ha fondamento matematico

### 4. Definizione assiomatica di probabilità (dovuta a Kolmogorov)

Sia  $S$  uno spazio campione finito, ad ogni evento  $A$  di  $S$  si associa un numero reale  $P(A)$ , detto probabilità dell’evento  $A$ , che soddisfa i seguenti assiomi:

1.  $0 \leq P(A) \leq 1$

2.  $P(S)=1$

3. Se  $A$  e  $B$  sono eventi mutuamente esclusivi (cioè  $A \cap B = \emptyset$ ) allora  $P(A \cup B) = P(A) + P(B)$

# CALCOLO COMBINATORIO E PROBABILITÀ

Proprietà ricavabili dalla definizione assiomatica:

1. Se **A** e **B** sono due eventi **qualunque** in S allora (**regola additiva**)

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

2. Se **A** è un evento di S allora

$$P(\bar{A}) = 1 - P(A)$$

**Probabilità condizionata** definizione:

Siano A e B due eventi di S con  $P(A) \neq 0$ . La probabilità dell'evento B nell'ipotesi che si sia già verificato l'evento A è detta probabilità condizionata ed è definita come:

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

Da cui segue

Prob condizionata

Prob condizionata

$$P(A)P(B | A) = P(A \cap B) = P(B \cap A) = P(B)P(A | B)$$

Proprietà commutativa

# CALCOLO COMBINATORIO E PROBABILITÀ

- **Esempio:** Supponiamo di voler determinare la probabilità che il numero ottenuto nel lancio di due dadi (somma) sia 7 sapendo che sul primo dado è uscito il numero 3.
- Il numero di combinazioni con il primo dado uguale a 3 è 6
  - (3,1), (3,2), (3,3), (3,4), (3,5), (3,6)
- Sola la combinazione (3,4) mi da 7, quindi la probabilità che esca 7 dato il primo dado 3 è  $P(B|A) = 1/6$

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

- Ritroviamo questo risultato usando la relazione
- La probabilità che sia  $A=\{3 \text{ sul primo dado}\}$  che  $B=\{4 \text{ sul secondo dado}\}$  si verifichino nel lancio dei due dadi (probabilità' A e B ) è data da 1 sola combinazione su 36,
  - 1/36
- La probabilità, invece, che il primo dado sia uguale a 3 è:  $P(A) = 1/6$
- $P(B|A) = (1/36) / (1/6) = 1/6$

# CALCOLO COMBINATORIO E PROBABILITÀ

Due eventi si dicono indipendenti se:

$$P(B|A)=P(B)$$

Esempio: Probabilità che sul secondo dado esca 4 sapendo che sul primo dado è uscito 3

E quindi anche

$$P(A|B)=P(A)$$

Nel caso di eventi indipendenti si deduce che

$$P(A \cap B) = P(A) * P(B)$$

Infatti:

$$P(A)P(B | A) = P(A \cap B) = P(B \cap A) = P(B)P(A | B)$$

ma

$$P(B|A)=P(B) \text{ e } P(A|B)=P(A)$$

per cui

$$P(A \cap B) = P(A) * P(B)$$

# CALCOLO COMBINATORIO E PROBABILITÀ

- Giocando a Poker classico, ho in mano una coppia di donne e un asso.
  - E' più conveniente chiedere tre carte scartando l'asso o chiederne solo due e tenersi l'asso?
- Non sempre in un gioco d'azzardo è univocamente identificabile la soluzione "più conveniente". **Consideriamo la possibilità di ottenere un Full o un Poker.**

Caso B



- Identifichiamo gli eventi favorevoli:
  - Eventi favorevoli **un asso e una donna**, **due assi** o **due donne**. Delle 27 carte nel mazzo solo **5 carte danno origine a eventi favorevoli** (perché nel mazzo restano 3 assi e due donne)
  - Voglio valutare il numero di combinazioni favorevoli tra tutte le combinazioni possibili, cioè in quanti modi posso ottenere combinazioni di due carte da un insieme di 5.
    - Eventi favorevoli: numero di combinazioni di 2 carte tra 5 =  $10 = 5! / [(5-2)! 2!]$
    - Probabilità di poker o full, nel caso B, =  $10/351 = 2.8\%$

351 = numero di elementi dello spazio campione

# CALCOLO COMBINATORIO E PROBABILITÀ

- Giocando a Poker classico, ho in mano una coppia di donne e un asso.
  - E' più conveniente chiedere tre carte scartando l'asso o chiederne solo due e tenersi l'asso?
- Non sempre in un gioco d'azzardo è univocamente identificabile la soluzione "più conveniente".  
**Consideriamo la possibilità di ottenere un Full o un Poker.**

- Identifichiamo gli eventi favorevoli:

Caso A



- Eventi favorevoli

- due donne + una carta X (diversa da donna): **POKER**
  - -> **25 combinazioni** (25 carte che possono accompagnare le due donne rimanenti)
- tre carte (diverse da donna) uguali: **FULL (non di DONNA)**
  - 7 carte per seme (8 meno donna); di queste 3 (diverse tra loro) in mano;  
 $4 \times 4 [\text{combinazioni di 3 tra 4}] + 3 \times 1 = \mathbf{19}$
- una (delle due rimanenti) donna + due carte X (diverse da donna) uguali: **FULL di DONNA**
  - ->  $2(\text{donne rimanenti}) \times \{ 4 \times 12 [\text{combinazioni di 2 tra 4}] + 3 \times 3 [\text{combinazioni di 2 tra 3}] \} = 2 \times 57 = \mathbf{114}$

Verificate

- Eventi favorevoli:  $25+19+114$ ; Probabilità di poker o full, nel caso A,  $= 158/2925 = 5.4\%$

# CALCOLO COMBINATORIO E PROBABILITÀ

- Esempio:
- Supponiamo di avere a che fare con una malattia rara che colpisce la popolazione con una frequenza di 2 malati ogni 100000 abitanti.
- $P(\text{malato}) = 2/100000 = 2 \times 10^{-5}$ 

**NOTA: probabilità nota a priori**
- Supponiamo di disporre di un test con le seguenti caratteristiche:
- **Sensibilità:** probabilità, cioè, di un risultato positivo se la persona è effettivamente malata
 

**Calibrazione. Conosco quale è l'effetto data la causa.**

  - $P(\text{pos} \mid \text{malato}) = 0.993$
- **Specificità:** probabilità, cioè, di un risultato negativo se la persona è sana
  - $P(\text{neg} \mid \text{sano}) = 0.9999$

*Il test è molto buono. La Sensibilità mi sta dicendo che identifica un malato se questo lo è effettivamente con una probabilità del 99.3 % mentre la specificità mi dice che dichiara una persona sana se questa lo è effettivamente con una probabilità del 99.99%*



# CALCOLO COMBINATORIO E PROBABILITÀ

- Supponiamo di voler valutare se sia utile o meno sottoporre a screening la popolazione solo in base ai risultati di questo test.
- Caso pratico: sottopongo a test  $10^6$  soggetti (screening), cosa mi aspetto si ottenga dal test?

$$P(pos | malato) = 0.993 \quad \text{Sensibilità}$$

$$P(neg | sano) = 0.9999 \quad \text{Specificità}$$

- **Uso una simulazione per verificare le mie previsioni.**
- Prendo  $10^6$  soggetti e casualmente assumo che siano malati o sani in base alle conoscenze a priori. In base alla sensibilità e specificità del test simulo la risposta del test per ogni soggetto.
- **Valuto quanti soggetti positivi al test sono effettivamente malati**
  - **$P(malato | pos)$**

# CALCOLO COMBINATORIO E PROBABILITÀ

## Teorema di Bayes

Sia  $A$  un evento di  $S$  con  $P(A) > 0$  e  $\{B_1, \dots, B_n\}$  una famiglia di eventi dello spazio campione  $S$  mutuamente esclusivi ed esaustivi, allora

$$P(B_k | A) = \frac{P(A | B_k)P(B_k)}{P(A)}$$

$$B_i \cap B_j = \emptyset \quad i \neq j \quad \text{Mutuamente esclusivi}$$

$$B_1 \cup B_2 \cup \dots \cup B_n = S \quad \text{Esaustivi}$$

Il teorema di Bayes è diretta conseguenza della definizione di probabilità condizionata

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

$$P(A)P(B | A) = P(A \cap B) = P(B \cap A) = P(B)P(A | B)$$

# CALCOLO COMBINATORIO E PROBABILITÀ

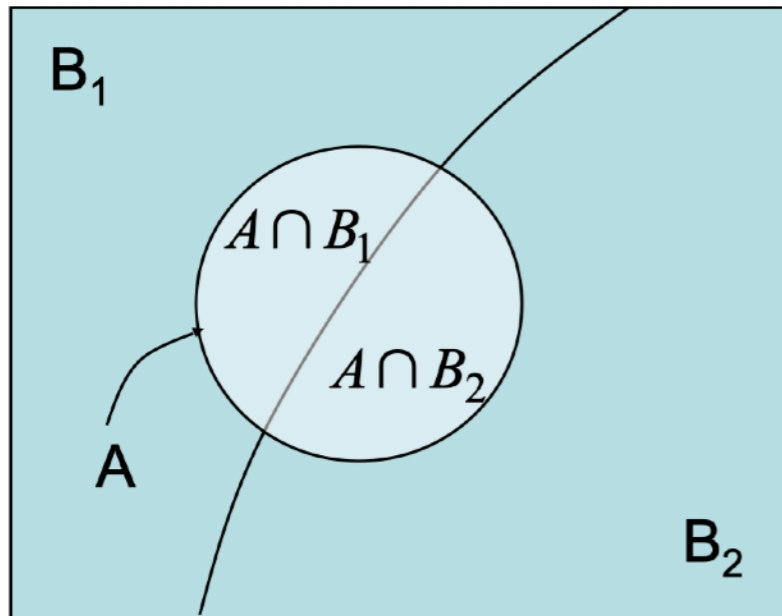
Dividere lo spazio campione in  $n$  eventi mutuamente esclusivi e esaustivi equivale a dividerlo in  $n$  classi.

Es.: Classi== malati di cuore e non; Gruppi di massa in uno spettro di Raggi Cosmici, etc.

Il teorema di Bayes risponde alla domanda:

*Supponiamo di aver ottenuto l'evento  $A$  qual è la probabilità che il mio elemento appartenga alla classe  $k$ ?*

# CALCOLO COMBINATORIO E PROBABILITÀ



$B_1$  e  $B_2$  esclusivi ed esaustivi

$$P(A) = P(A \cap B_1) + P(A \cap B_2)$$

Ma per la definizione di probabilità condizionata

$$P(A \cap B_1) = P(A | B_1)P(B_1)$$

Da cui si dimostra il

## Teorema della probabilità totale

Sia  $A$  un evento di  $S$  e  $\{B_1, \dots, B_n\}$  una famiglia di eventi di  $S$  mutuamente esclusivi e esaustivi

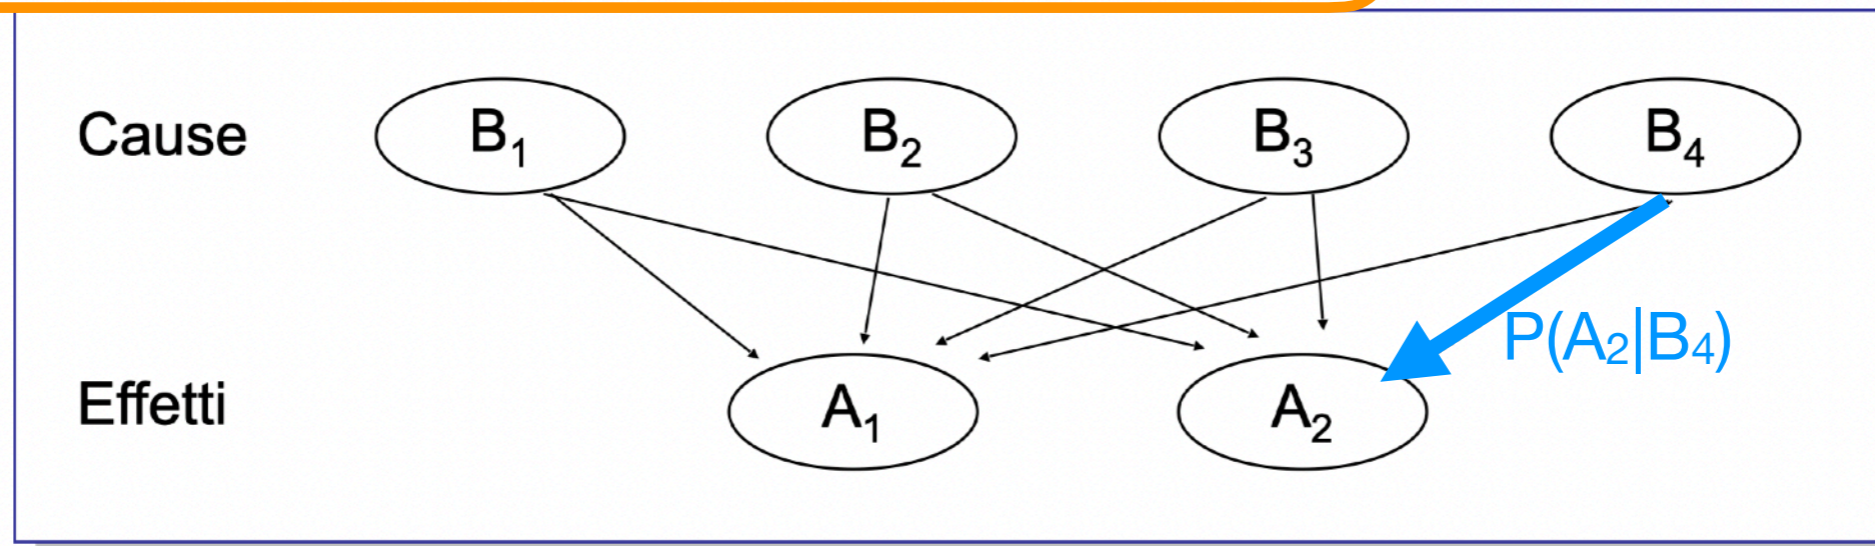
$$P(A) = P(A | B_1)P(B_1) + \dots + P(A | B_n)P(B_n)$$

Usando il teorema della probabilità totale, il teorema di Bayes si può riscrivere come:

$$P(B_k | A) = \frac{P(A | B_k)P(B_k)}{\sum_{k=1}^n P(A | B_k)P(B_k)}$$

# CALCOLO COMBINATORIO E PROBABILITÀ

Analizziamo una misura in termini di causa ed effetto



Lo spazio degli eventi è separato in  $n$  classi mutuamente esclusive ed esaustive che rappresentano tutte le possibili cause ( $B_1, \dots, B_4$  nella figura).

Ogni causa può dare origine con probabilità diversa ad alcuni effetti ( $A_1, A_2$  nella figura).

La probabilità che l'effetto  $A_1$  sia dovuto alla causa  $B_2$  è normalmente noto e rappresenta la probabilità che si verifichi l'effetto  $A_1$  quando si è verificata la causa  $B_2$ .

$P(A_1|B_2)$

In una misura tipicamente vedo (misuro) l'effetto ( $A_1$ ) e mi chiedo a quale possibile causa sia dovuto.

$P(B_k|A_1)$ .

Il teorema di Bayes mi aiuta in questo.

$$P(B_k | A_i) = \frac{P(A_i | B_k) P(B_k)}{\sum_j P(A_i | B_j) P(B_j)}$$

# CALCOLO COMBINATORIO E PROBABILITÀ

$$P(B_k | A_i) = \frac{P(A_i | B_k) P(B_k)}{\sum_j P(A_i | B_j) P(B_j)}$$

Notiamo come sia la specificità che la sensibilità del test sono due esempi di probabilità condizionata.

Misura

Ora supponiamo di voler applicare il test ad un campione di persone a caso la domanda che ci poniamo è:

*“quanti di coloro che sono risultati positivi al test sono effettivamente malati e quanti invece sono sani?”*

Questo equivale ad identificare la probabilità (condizionata) che un soggetto positivo al test sia effettivamente malato

Questa è conoscenza **a priori**

$$P(\text{malato} | \text{pos}) = \frac{P(\text{pos} | \text{malato})P(\text{malato})}{P(\text{pos} | \text{malato})P(\text{malato}) + P(\text{pos} | \text{sano})P(\text{sano})}$$

# CALCOLO COMBINATORIO E PROBABILITÀ

$$P(\text{malato} | \text{pos}) = \frac{P(\text{pos} | \text{malato})P(\text{malato})}{P(\text{pos} | \text{malato})P(\text{malato}) + P(\text{pos} | \text{sano})P(\text{sano})}$$

$$P(\text{pos} | \text{malato}) = 0.993$$

Sensibilità del test

$$P(\text{malato}) = 2 \cdot 10^{-5}$$

Conoscenza a priori

$$P(\text{pos} | \text{sano}) = 1 - P(\text{neg} | \text{sano}) = 1 - 0.9999 = 1 \cdot 10^{-4}$$

Da specificità

$$P(\text{sano}) = 1 - P(\text{malato}) = 0.99998$$

Conoscenza a priori

Da cui

$$P(\text{malato} | \text{pos}) = 0.1656$$

Per cui di coloro che risultano positivi al test solo poco più del 16% sono effettivamente malati i rimanenti (84%) sono sani ma erroneamente indicati come malati (falsi positivi)

# CALCOLO COMBINATORIO E PROBABILITÀ

Quant'è invece la frazione di coloro che risultano negativi al test e sono effettivamente sani

Questo equivale a calcolare la  $P(\text{sano}|\text{neg})$

$$P(\text{sano} | \text{neg}) = \frac{P(\text{neg} | \text{sano})P(\text{sano})}{P(\text{neg} | \text{sano})P(\text{sano}) + P(\text{neg} | \text{malato})P(\text{malato})}$$

Con un calcolo analogo al precedente si trova che

$$P(\text{sano} | \text{neg}) = 0.99999999$$

Quindi se il risultato del test è negativo, la probabilità di essere sani è estremamente elevata o, inversamente, la probabilità che un malato risulti negativo al test (falso negativo) è estremamente bassa.



---

**FINE**

---