

# Dalla FREQUENZA alla PROBABILITA'

1

## Esempio clinico - variabile dicotomica

$X$  : presenza/assenza di ipertensione, uomo 50-55 anni.

Si osservano 1000 individui, 380 sono ipertesi, si conclude che la **proporzione (frequenza) di ipertesi è 0.38=38%**

Questa è una **stima** della **probabilità (ignota)** di ipertensione nell'intera popolazione - uomo 50-55 anni.


La probabilità di ipertensione 'vera' potrebbe essere

$P(X = \text{'Iperteso'}) = 0.40 = 40\%$ .

2

## La Probabilità : un meccanismo che lavora dietro le quinte

Guida la realizzazione dei fenomeni aleatori ed in generale la manifestazione delle variabili sulle unità statistiche



La performance di un balletto dipende dalle scelte del coreografo e da altri elementi casuali propri del momento

3

Nella statistica descrittiva si parla di **variabili/rilevazioni e dati/modalità...**

Nella teoria della Probabilità si parla di **esperimenti (rilevazioni) ed eventi (modalità)**

$X$  : presenza/assenza di ipertensione, uomo 50-55 anni.

$X$  è una variabile che ottengo con un semplice esperimento : valutazione della pressione del soggetto.



L'esito della valutazione può dare origine ai due eventi (**eventi semplici**)


$X = \text{'iperteso'}$  e  $X = \text{'non iperteso'}$

Questi sono i dati che verranno osservati.

4

## La Probabilità agisce dietro le quinte sulla singola unità statistica nel determinare la realizzazione della variabile osservata

(a differenza della frequenza relativa)



Globalmente il numero di SI che osservo sui 1000 analizzati tenderà ad essere uguale ad un 40%

5


## Probabilità

### La PROBABILITÀ MISURA L'INCERTEZZA del verificarsi di un evento

6

### Definizione di PROBABILITÀ : ASSIOMI

1. La probabilità di osservare un evento è compresa tra 0 (0%) e 1 (100%)



2. La somma delle probabilità di tutti i possibili eventi è 1 (100%)



3. La probabilità è una funzione additiva (eventi incompatibili tra di loro)

$$P(X = \text{'iperteso'}) + P(X = \text{'non iperteso'}) = 1 = 100\%$$

7

### Definizione di PROBABILITÀ :

• **CLASSICA**: "La probabilità di un evento A è pari al rapporto fra i casi favorevoli all'evento e tutti i casi ugualmente possibili"

• **FREQUENTISTA**: "La probabilità di un evento A è approssimata dalla frequenza relativa con cui l'evento si manifesta, qualora si ripeta il medesimo esperimento un numero molto elevato di volte"

• **SOGGETIVISTA**: "La probabilità di un evento A misura il grado di fiducia, espresso fra 0 e 1, che un individuo (coerente) attribuisce all'evento A, sulla base delle informazioni in suo possesso"

8

## La Probabilità : un concetto che lavora dietro le quinte



Figlio con mutazione genetica in funzione del patrimonio dei genitori (leggi della natura)



Risposta ad un farmaco (studio empirico)




Valutazione medica (leggi della natura, studio empirico, valutazione soggettiva)


9

## Esempio genetica - UNA VARIABILE dicotomica

X : colore occhi di un figlio (C=chiaro/S=scuro)



Senza fare esperimenti di alcun tipo, **conosco la 'legge che lavora dietro le quinte'** del fenomeno: S è dominante.



Figlio sarà S = SC o C = CC a seconda di cosa eredita dal padre.

$$P(S) = P(C) = 0.5 = 50\%$$

Se si osserva un campione di figli di padri e madri di questa tipologia, circa il 50% sarà C e circa il 50% sarà S.

10


## Esempio antropometria - una VARIABILE discreta

X : classe ponderale bambini in età scolare  
(NW=normopeso, OW=sovrappeso, OB=obeso)

Si osservano 1000 bambini:

X	f(x)	Frequenza relativa
NW	700	0.70 = 70%
OW	230	0.23 = 23%
OB	70	0.07 = 7%

Queste frequenze **stimano le probabilità** (ignote) relative all'intera popolazione, che potrebbero essere:




11

## Esempio epidemiologia - UNA VARIABILE continua

PAD misurata in 1500 uomini 35 - 44 anni.

Istogramma ed approssimazione Gaussiana che **stimano l'andamento della probabilità** (ignota) di questo fenomeno



Se l'ipertensione diastolica viene definita come il superamento di 80 mmHg, allora la **stima della probabilità** (ignota) di avere ipertensione è 0.50=50%.

12

## Simboli che utilizzeremo

- Unione  $\cup$  (oppure)
- Intersezione  $\cap$  (e)
- Condizionata  $|$  (dato che)
- $\bar{A}$  complementare di A

13


## Eventi semplici - Unione

L'osservazione di X (esperimento) da luogo ad un insieme di valori (eventi semplici)

NW      OW      OB

Gli eventi **composti** sono l'unione di piu' eventi semplici, e.g.

**OW U OB** che in altre parole è OW oppure OB



L'evento composto OW U OB è osservato quando  
OW oppure OB

14

## Eventi semplici - Unione

$$P(OW \cup OB) = P(OW) + P(OB) = 0.23 + 0.07 = 0.30$$

In alternativa, si puo' ragionare come segue:


- 1) Su 100 persone, i numeri stimati di OW e di OB sono  
 $100 * P(OW) = 100 * 0.23 = 23$        $100 * P(OB) = 100 * 0.07 = 7$
- 2) In totale  $23 + 7 = 30$  persone sono OW oppure OB
- 3) Si ragionava su 100 persone quindi la stima di  
 $P(OW \cup OB) \hat{=} 30/100 = 0.30$

15

## Evento complementare di un evento (semplice o composto)

La stessa probabilità,  $P(OW \cup OB)$ , posso ottenerla indirettamente ricorrendo a tutti gli eventi che **non** avverano OW o OB  $\rightarrow$  NW

L'evento normopeso è il **complementare** dell'evento sovrappeso o obeso ( $OW \cup OB$ )



$$\begin{aligned} P(OW \cup OB) &= 1 - \overline{P(OW \cup OB)} \\ &= 1 - P(NW) \\ &= 1 - 0.70 = 0.30 = 30\% \end{aligned}$$


$$\rightarrow \overline{P(OW \cup OB)} = P(NW)$$

16

## Evento complementare di un evento (semplice o composto)

In altre parole, il complementare di un evento è tutto ciò che non appartiene a quell'evento.

Ad esempio, il complementare dell'evento 'iperteso' è  $\overline{\text{iperteso}}$  o 'non iperteso'



17

## Esempio antropometria - DUE VARIABILI discrete

$X$ : classe ponderale bambini in età scolare

(NW=normopeso, OW=sovrappeso, OB=obeso).

$G$ : sesso del bambino (M=maschio, F=femmina)

Si osserva un campione di 1000 bambini:

$G=\text{sesso}$	$X=\text{Classe Ponderale}$			<u>Totale</u>
	<u>NW</u>	<u>OW</u>	<u>OB</u>	
<b>F</b>	300	85	15	400
<b>M</b>	400	145	55	600
<b>Totale</b>	700	230	70	1000

18

## Probabilità Condizionata - variabili discrete

La probabilità che guida il comportamento di  $X$  lavora dietro le quinte nella stessa maniera per maschi e femmine?

	<u>NW</u>	<u>OW</u>	<u>OB</u>	
F	300	85	15	400
M	400	145	55	600
<b>Totale</b>	700	230	70	1000

Il fenomeno  $X$  si può descrivere separatamente per riga in  $M$  e  $F$  ottenendo le seguenti frequenze relative:

$G=\text{sesso}$	$X=\text{Classe Ponderale}$			<u>Totale</u>
	<u>NW</u>	<u>OW</u>	<u>OB</u>	
<b>F</b>	$0.75=300/400$	$0.21$	$0.04$	$1=100\%$
<b>M</b>	$0.67=400/600$	$0.24$	$0.09$	$1=100\%$
<b>F U M</b>	$0.70=700/1000$	$0.23$	$0.07$	$1=100\%$

## Probabilità Condizionata - variabili discrete

$G=\text{sesso}$	$X=\text{Classe Ponderale}$			<u>Totale</u>
	<u>NW</u>	<u>OW</u>	<u>OB</u>	
<b>F</b>	$0.75$	$0.21$	$0.04$	$1=100\%$
<b>M</b>	$0.67$	$0.24$	$0.09$	$1=100\%$
<b>F U M</b>	$0.70$	$0.23$	$0.07$	$1=100\%$

Le frequenze  $0.75=75\%$ ,  $0.21=21\%$ ,  $0.04=4\%$  sono stime della probabilità di essere nelle classi ponderali **condizionata al fatto che si è F**

$$P(\text{NW}|\text{F}) \quad P(\text{OW}|\text{F}) \quad P(\text{OB}|\text{F})$$

dato che ..

L'evento condizionante ( $F$ ) riduce lo spazio degli eventi possibili al solo mondo femminile  $\rightarrow$  il denominatore non è più 1000 ma 400!

## Probabilità Condizionata - variabili discrete

G= sesso	X=Classe Ponderale			Totale
	NW	OW	OB	
F	0.75	0.21	0.04	1=100%
M	0.67	0.24	0.09	1=100%
F U M	0.70	0.23	0.07	1=100%

Analogamente, la seconda riga stima le probabilità

$$P(NW|M) \quad P(OW|M) \quad P(OB|M)$$

La probabilità che un bambino sia sovrappeso dato che è maschio è del 24%.

21

## Probabilità Condizionata - variabili discrete

G= sesso	X=Classe Ponderale			Totale
	NW	OW	OB	
F	0.75	0.21	0.04	1=100%
M	0.67	0.24	0.09	1=100%
F U M	0.70	0.23	0.07	1=100%

Siamo portati a sospettare che

$$P(X = \dots | F) \text{ sia diversa da } P(X = \dots | M)$$

$$\text{e quindi anche da } P(X = \dots | F U M)$$

**Le variabili osservate si dice che sono (forse) DIPENDENTI perché il sesso pare che influenzi il comportamento della classe ponderale**

22

**Cosa mi aspetterei di osservare nel caso in cui il sesso non influenzi la classe ponderale (X e G indipendenti) ?**

G= sesso	X=Classe Ponderale			Totale
	NW	OW	OB	
F	400 · 0.7	400 · 0.23	400 · 0.07	400
M	600 · 0.7	600 · 0.23	600 · 0.07	600
F U M	700	230	70	1000

Tra le femmine mi aspetterei di osservare 280 normopeso, 92 sovrappeso e 28 obese ...

NOTA: 280 è pari al prodotto dei totali di riga (400) e colonna (700) diviso per il totale (1000)

$$\rightarrow 280 = (400 \cdot 700) / 1000$$

23

## Probabilità Condizionata - variabili discrete

Da un punto di vista matematico il fenomeno G=sesso si può descrivere separatamente per colonna in NW, OW e OB ottenendo le frequenze relative rappresentate sotto

G= sesso	X=Classe Ponderale			Totale
	NW	OW	OB	
F	0.43	0.37	0.21	0.40
M	0.57	0.63	0.79	0.60
F U M	1	1	1	1

Concludendo che siamo portati a sospettare che

$$P(G = \dots | NW) \text{ sia diversa da } P(G = \dots | OW) \dots$$

**Tuttavia è poco naturale pensare che la classe ponderale influenzi il comportamento del sesso...**

24

## Probabilità Congiunta - Intersezione

Il fenomeno costituito dalla coppia di variabili  $G$  e  $X$  si può descrivere globalmente ottenendo le frequenze relative su due variabili rappresentate sotto

$G=\text{sexo}$	$X=\text{Classe Ponderale}$			Totale
	NW	OW	OB	
F	0.30=300/1000	0.085	0.015	0.400
M	0.400	0.145	0.055	0.600
Totale	0.700	0.230	0.070	1=100%

$P(F \cap NW)$  che in altre parole è  $P(F \text{ e } NW)$

Si noti che la tabella è additiva in riga e colonna

0.30 stima la probabilità di essere femmina e normopeso

25


## Probabilità Congiunta - Intersezione

L'evento  $F \cap NW$

è un **evento composto** che coinvolge due variabili

intersezione di **due eventi semplici**,

uno per la variabile sesso, l'altro per la variabile classe ponderale



26


## Probabilità Congiunta - Intersezione

La probabilità congiunta si può ricavare anche tramite la probabilità condizionata, infatti

$$P(NW | F) = \frac{300}{400} = \frac{300/1000}{400/1000} = \frac{P(NW \cap F)}{P(F)}$$



$$P(F \cap NW) = P(F) * P(NW | F) = 0.40 * 0.75 = 0.30$$



Oppure, analogamente :

$$P(F \cap NW) = P(NW) * P(F | NW) = 0.7 * 0.43 = 0.30$$

27

## Probabilità Congiunta - Intersezione

In una scuola, le allieve femmine sono il **40%**. Sapendo che il **75%** delle femmine in età scolare è normopeso, che percentuale di femmine normopeso mi aspetto nella scuola?

1) Su 100 persone, il numero stimato di femmine è  $100 * P(F) = 100 * 0.40 = 40$

2) Su queste 40 femmine, il numero stimato di NW è  $40 * P(NW | F) = 40 * 0.75 = 30$

3) Si ragiona su 100 persone la stima di

$$P(F \cap NW) \text{ è } 30/100 = 0.30$$

28

## Probabilità Congiunta e Indipendenza

E se il sesso e la classe ponderale fossero **indipendenti** ?  
Cioè, se il sesso non influisse sulla classe ponderale ?

G=sesso	X=Classe Ponderale			Totale
	NW	OW	OB	
F	0.70	0.23	0.07	0.4
M	0.70	0.23	0.07	0.6
F U M	0.70	0.23	0.07	1

Dovrei considerare che la distribuzione della classe ponderale nelle **Femmine** e nei **Maschi** sia uguale a quella marginale

→  $P(NW|F) = P(NW|M) = P(NW)$

↓  
 $P(F \cap NW) = P(F) * P(NW)$   
 $= 0.4 * 0.70 = 0.28 \neq 0.30$

29

## Definizione di Indipendenza

Definizione:

Due eventi/variabili A e B sono dette indipendenti se:  
il verificarsi di uno non dice nulla riguardo al verificarsi dell'altro

•  $P(NW|F) = P(NW)$

•  $P(F|NW) = P(F)$

} Proprietà di simmetria

↓  
 •  $P(NW \cap F) = P(F) * P(NW|F) = P(F) * P(NW)$  oppure  
 •  $P(NW \cap F) = P(NW) * P(F|NW) = P(NW) * P(F)$

30

## Definizione di Indipendenza

Definizione:

Due eventi/variabili A e B sono dette indipendenti se:

•  $P(A|B) = P(A)$

•  $P(B|A) = P(B)$

} Proprietà di simmetria

↓  
 •  $P(A \cap B) = P(B) * P(A|B) = P(B) * P(A)$  oppure  
 •  $P(A \cap B) = P(A) * P(B|A) = P(A) * P(B)$

31

...In Conclusione...

La probabilità dell'intersezione di due eventi A e B è pari a:

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

Se A e B non sono indipendenti

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


Se A e B sono indipendenti

32



Dalla probabilità congiunta alla probabilità condizionata ...

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



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

33

## Unione - 2 variabili discrete

P=	X=Classe Ponderale			Totale
	NW	OW	OB	
ipertensione				
Sì	14	21	10	45
No	686	229	40	955
Totale	700	250	50	1000

Stimare la probabilità di essere iperteso oppure di essere obeso.

$$P(\text{Sì} \cup \text{OB}) \text{ che in altre parole è } P(\text{Sì} \text{ o } \text{OB})$$

Si tratta di un 'o' (oppure) non esclusivo.

34

### Ragionamento 1)

Stimare la probabilità di essere iperteso oppure di essere obeso.

P=	X=Classe Ponderale			Totale
	NW	OW	OB	
ipertensione				
Sì	14	21	10	45
No	686	229	40	955
Totale	700	250	50	1000

Sembrerebbe naturale sommare le stime delle corrispondenti probabilità' ( $P(\text{Sì})=4.5\% + P(\text{OB})=5\%$ ), poiché entrambe le condizioni avvalorano il fatto di essere o iperteso o obeso!

Tuttavia questo porterebbe a duplicare la presenza della condizione di Sì e OB che va quindi sottratta:

$$P(\text{Sì} \cup \text{OB}) = P(\text{Sì}) + P(\text{OB}) - P(\text{Sì} \cap \text{OB}) \\ = 0.045 + 0.050 - 0.010 = 0.085$$

35

### Ragionamento 2)

Stimare la probabilità di essere iperteso oppure di essere obeso.

P=	X=Classe Ponderale			Totale
	NW	OW	OB	
ipertensione				
Sì	14	21	10	45
No	686	229	40	955
Totale	700	250	50	1000

Ipertesi  
 $P(\text{Sì})=4.5\%$

Non ipertesi obesi  
 $P(\text{No} \cap \text{OB}) = 4\%$

Entrambe le condizioni avvalorano il fatto di essere o iperteso o obeso

-> è naturale sommare le stime delle corrispondenti probabilità:


$$P(\text{Sì} \cup \text{OB}) = P(\text{Sì}) + P(\text{NonOB}) = 0.045 + 0.040 = 0.085$$

36

## Unione - 2 variabili discrete


Quale differenza c'è tra il ragionamento 1) e 2) ?

- Il ragionamento 2) considera eventi INCOMPATIBILI (o mutuamente esclusivi)



$$P(S \cap OB) = \emptyset$$

- Il ragionamento 1) no!  
→ Gli eventi iperteso e obeso sono COMPATIBILI



$$P(S \cap OB) \neq \emptyset$$

37

## Unione - 2 variabili discrete

**Stimare la probabilità di essere iperteso oppure di essere obeso.**

Avendo tutte le informazioni in tabella:

P=	X=Classe Ponderale			Totale
	NW	OW	OB	
ipertensione				
Sì	14	21	10	45
No	686	229	40	955
Totale	700	250	50	1000


$$\begin{aligned} P(S \cup OB) &= P(S \cap NW) + P(S \cap OW) + P(S \cap OB) + P(\text{No} \cap OB) = \\ &= 14/1000 + 21/1000 + 10/1000 + 40/1000 = \\ &= 85/1000 = 0.085 = 8.5\% \end{aligned}$$

38

## ...In Conclusione...


La probabilità dell'unione di due eventi A e B è pari a:

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



**Se A e B sono compatibili**

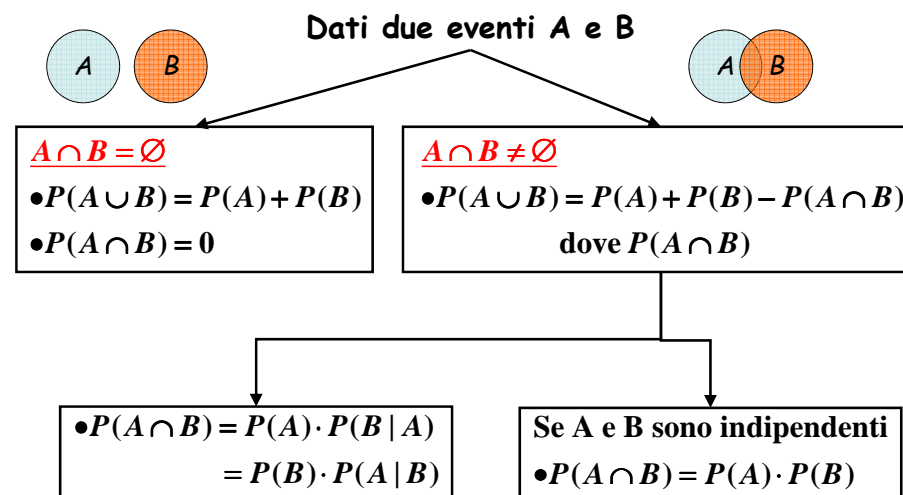
$$P(A \cup B) = P(A) + P(B)$$



**Se A e B sono incompatibili**

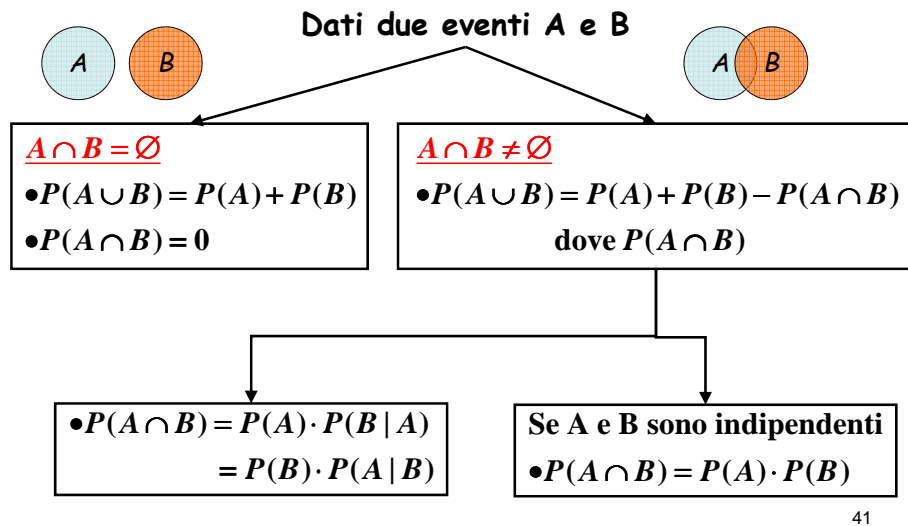
39

## Riepilogando



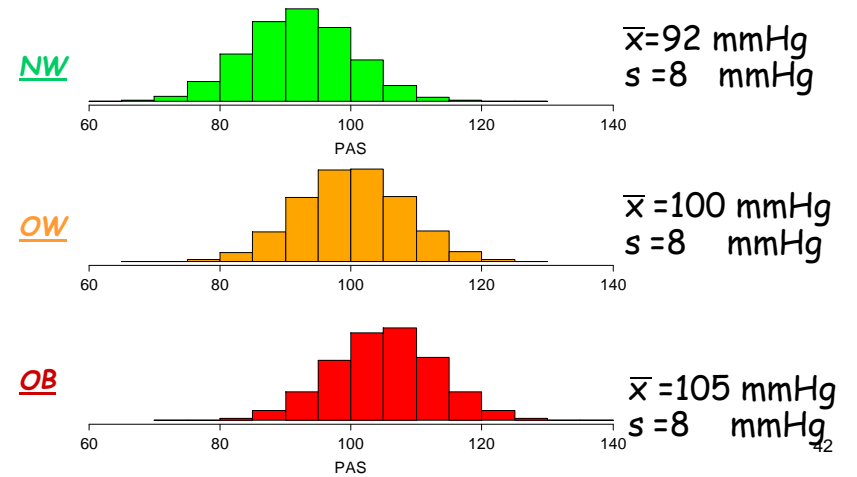
40

## Riepilogando




## Probabilità Condizionata - variabili continue

PAS e classe ponderale in bambine/bambini di 4 anni




## Probabilità Congiunta - Intersezione



Qual è la probabilità che un bambino sia NW e con PAS > 110 mmHg?

43

## Probabilità Congiunta - Intersezione



Qual è la probabilità che un bambino sia NW e con PAS > 110 mmHg?

$$P(NW \cap PAS > 110) = P(NW) * P(PAS > 110 | NW) = 0.7 * 0.01 = 0.007 = 0.7\%$$

A sample of 35 patients diagnosed with colon carcinoma in Finland during 1985-94, followed up 10 years

Time (yy)	S(t <sub>i+1</sub>  t <sub>i</sub> )
[0-1)	0.77143
[1-2)	0.92308
[2-3)	0.76190
[3-4)	0.85185
[4-5)	1.00000
[5-6)	1.00000
[6-7)	1.00000
[7-8)	1.00000
[8-9)	0.55556
[9-10)	1.00000

→ Probabilità di sopravvivere al primo anno dopo la diagnosi

→  $P(2|1) = P(2 \cap 1) / P(1)$   
 Probabilità di giungere vivi al secondo anno | si è sopravvissuti al primo

$$P(2 \cap 1) = P(2|1) * P(1)$$

$$P(2) = P(2 \cap 1)$$

↓

Probabilità di sopravvivere fino al secondo anno

45

A sample of 35 patients diagnosed with colon carcinoma in Finland during 1985-94, followed up 10 years

Time (yy)	S(t <sub>i+1</sub>  t <sub>i</sub> )
[0-1)	0.77143
[1-2)	0.92308
[2-3)	0.76190
[3-4)	0.85185
[4-5)	1.00000
[5-6)	1.00000
[6-7)	1.00000
[7-8)	1.00000
[8-9)	0.55556
[9-10)	1.00000

Qual è la probabilità di essere ancora vivi dopo 5 anni dalla diagnosi?

$$P(5) = P(5|4) * P(4) =$$

$$P(5|4) * P(4|3) * P(3) =$$

$$P(5|4) * P(4|3) * P(3|2) * P(2|1) * P(1) =$$

$$0.46216$$

46

A sample of 35 patients diagnosed with colon carcinoma in Finland during 1985-94, followed up 10 years

Time (yy)	S(t <sub>i+1</sub>  t <sub>i</sub> )
[0-1)	0.77143
[1-2)	0.92308
[2-3)	0.76190
[3-4)	0.85185

Qual è la probabilità di essere ancora vivi dopo 10 anni dalla diagnosi, dato che si è sopravvissuti i primi 5?

$$P(10|5) = P(10 \cap 5) / P(5) = P(10) / P(5) =$$

$$P(10|9) * P(9|8) * P(8|7) * P(7|6) * P(6|5) * P(5|4) * P(4|3) * P(3|2) * P(2|1) * P(1) /$$

$$P(5|4) * P(4|3) * P(3|2) * P(2|1) * P(1) =$$

$$P(10|9) * P(9|8) * P(8|7) * P(7|6) * P(6|5) = 0.55556$$