

Para entender os conceitos de probabilidade e algumas técnicas, iremos usar o problema do cominho aleatório em 1-D. Além de ser um dos modelos mais simples, tem aplicações no mundo real de partículas em reações viscões.

Antes, alguns conceitos básicos de prob.

→ Probabilidades surgem quando não conseguimos prover com absoluta certeza o resultado de uma observação em um dado sistema.

Preparamos o sistema sempre da mesma maneira, mas os resultados das observações são diferentes.

→ Fica dito que para se falar de prob. precisamos obter (ou fazer medidas) mais que uma vez sobre o sistema preparado exatamente da mesma maneira.

Da modo equivalente podemos ter um conjunto de sistemas preparados da mesma maneira e observar cada membro do conjunto (os sistemas devem ser idênticos e independentes).

A esse conjunto de sistemas idênticos damos o nome de Memeke (grupo em frases).

→ Assim não faz sentido falar de prob. para um único sistema. Temos sempre que pensar no sistema como parte de um ensemble e as prob. irão depender de que ensemble específico estamos considerando.

Mais formalmente: considere um ensemble Σ de sistemas idênticos S .

A prob. de ocorrer um evento x (em certo valor p/ alguma medida)

$$\hat{P}(x) = \lim_{N(\Sigma) \rightarrow \infty} \frac{n(x)}{N(\Sigma)} \quad \begin{array}{l} \text{\# de total de} \\ \text{sistemas no ensemble} \end{array}$$

\sum

$n(x)$: # de sistemas que exibem o evento x

Fico dito que $0 \leq \hat{P}(x) \leq 1$

Se $\hat{P}(x) = 0$ → nenhum sistema exibe o evento x , mesmo para N sistemas

Se $\hat{P}(x) = 1$ → Todos os sistemas exibem o evento x

Por exemplo p/ uma moeda: diremos ter N moedas idênticas e jogar cada uma de modo idêntico. Então contar o número de vezes que temos o evento x (coro).

Essa é uma visão bem objetivo e experimental de probabilidade.

Uma outra possibilidade é considerar todos os possíveis resultados de um experimento, que devem ser mutuamente exclusivos.

Este conjunto é chamado espaço amostral

Para 1 dado: 1 cara, coroa

1 dado: {1, 2, 3, 4, 5, 6}

2 dados: {cara cara, cara coroa, coroa cara, coroa coroa}

Note que há mais de uma possibilidade de espaço amostral. Para o caso de 2 dados por exemplo podemos considerar: {2 caras, 1 cara, 0 caras}
{0 caras, pelo menos 1 cara}

Só temos que tomar cuidado p/ que os resultados sejam mutuamente excludentes!

Cada resultado (ou ponto) no espaço amostral é considerado um ponto do espaço amostral. E a cada evento associamos uma probabilidade.

ponto	cara	cara
prob	$\frac{1}{2}$	$\frac{1}{2}$

espaço amostral
uniforme

2 caras	1 cara	0 caras
$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$

espaço amostral
não uniforme

Com isso definimos a prob. de 4 eventos somados as prob. de cada ponto "favorável" aos eventos

$$\text{prob. de pelo menos 1 cara} = \text{prob. de 1 cara} + \text{prob. de 2 caras}$$

$$\frac{1}{2} + \frac{1}{4} = \frac{3}{4}$$

Note que para espaços amostrais uniformes temos

$$\text{prob.} = \frac{\# \text{ de eventos (pontos) favoráveis ao evento}}{\# \text{ total de pontos do espaço amostral}}$$

Nessa definição temos que assumir a priori o conceito de prob.

No caso do espaço amostral uniforme pode-se argumentar em termos de simetria. Não temos nenhuma informação que leve a privilegiar um dos eventos, assim devem ser equiprováveis

Essas interpretações de prob. são chamadas de frequentistas: associam prob. com a freq. que um evento ocorre. Existem outras definições ou interpretações que são mais subjetivas. A principal delas é a Bayesiana, baseada em um trabalho do clérigo e matemático amador Thomas Bayes de 1763

Na interpretação frequentista (ou observacional) a dist. de prob. é uma propriedade do sistema sendo observado e não depende do observador. Já na interpretação de Bayes ela depende do observador.

Independentemente da interpretação probabilística desse axioma, os resultados possíveis de um experimento (que podem ser vistos como axiomas)

1) Se existem M possíveis eventos x_i , então

$$\sum_{i=1}^M P(x_i) = 1 \quad \text{condição de normalização}$$

↳ cada sistema do ensemble ter que sair um dos possíveis eventos

2) Se temos dois eventos distintos x_1 e x_2 (ou seja, são mutuamente excludentes)

$$P(x_1 \text{ ou } x_2) = P(x_1) + P(x_2)$$

↳ prob. de obter 1 ou 3 quando joga 1 único dado
 $\rightarrow 1/6 + 1/6 = 2/6 = 1/3$

3) Para dois eventos independentes (um não influencia o outro)

$$P(x_1 \text{ e } x_2) = P(x_1) P(x_2)$$

↳ prob. que ambos ocorram. Pode ser um após o outro ou ao mesmo tempo, já que são independentes

$x_1 \text{ e } x_2$ é um evento composto

Exemplo: prob. de obter 1 num dado e 2 em outro

$$P(1 \text{ e } 2) = 1/6 \cdot 1/6 = 1/36$$

Note que a ordem é importante, já que não consideramos a possibilidade de obter 2 no primeiro e 1 no segundo. Estamos identificando os dados!

Se usarmos a def. de prob. como

$$\frac{\# \text{ de eventos } E}{\# \text{ total de eventos}}$$

\rightarrow assumimos que todos os eventos são equiprováveis

Poderemos facilmente deduzir as regras acima.

de eventos onde x_1 ou x_2 ocorrem = # de eventos x_1 + # de eventos x_2

No caso de dados espaço amostral é $\{1, 2, 3, 4, 5, 6\} \rightarrow 6$ eventos

de eventos onde ocorre 1 ou 2 $\rightarrow 2$ eventos

$$\text{Logo } P(1 \text{ ou } 2) = 2/6 = P(1) + P(2) = 1/6 + 1/6$$

No caso de dois eventos x_1 e x_2 ocorrem temos que considerar o espaço amostral de um experimento em 2 sistemas. Logo é # de de eventos o quadrado do caso de 1 único sistema

E o número de eventos onde ocorre x_1 e x_2 é o produto das # de eventos individuais.

No caso de 2 dados

espaço amostral: 11, 12, 13, 14, 15, 16

↓ 21, 22, ... 26

36 elementos 31, 32, ... 36

:

61, 62, ..., 66

de eventos com 1 e depois 2 $\rightarrow 1 \rightarrow P(1, 2) = 1/36$

Um caso mais interessante é prob de obter $x_1 \leq 3$ e $x_2 \leq 2$

$$P(X_1 \leq 3) = \frac{3}{6} = \frac{1}{2} \quad \text{há três possib., } X_1=1, 2 \text{ ou } 3$$

$$P(X_2 \leq 2) = \frac{2}{6} = \frac{1}{3} \quad \text{há duas possib } X_2=1 \text{ ou } 2$$

$$P(X_1 \leq 3 \text{ e } X_2 \leq 2) = \frac{6}{36} = \frac{1}{6} = \frac{1}{2} \cdot \frac{1}{3}$$

↳ há 6 possibilidades e isso deve que é o produto da # de possib. de X_1 vezes a # de possib. de X_2 ; poss combinar cada possib de X_1 com \forall outros de X_2

Nesse caso fico devo pq a prob. do evento conjunto fatora nas prob. dos eventos individuais

Como já mencionado, independentemente das interpretações probabilísticas devem obedecer a alguns regras básicas

$$1) P(i) \geq 0 \quad 2) \sum P(i) = 1$$

$$3) P(i \cup j) = P(i) + P(j) \quad \text{p/ eventos } i \text{ e } j \text{ mutuamente excludentes}$$

$$4) P(i \cdot j) = P(i)P(j) \quad \text{p/ eventos independentes}$$

Em 1933 o matemático russo A.N. Kolmogorov formulou um conjunto completo de axiomas para a definição matemática de probabilidade (são os três primeiros regras)

Formalmente pode-se definir um espaço de probabilidades usando o espaço amostral, os eventos como "pontos", e as probabilidades associados aos eventos como "medidas" neste espaço

→ A distribuição de prob. $P(x)$ de uma dada variável aleatória x , é a descrição mais completa do sistema (do ponto de vista estatístico)

E interessante definir o valor esperado (ou valor médio ou primeiro momento) da variável aleatória.
É a soma ponderada de todos os valores possíveis.

Definição:

→ tb se usa a notação $E[x]$ ou $\langle x \rangle$

$$\bar{x} = \frac{\sum P(x_i) x_i}{\sum P(x_i)} \rightarrow \text{caso } P(x_i) \text{ não esteja normalizado.}$$

\bar{x} fornece informações sobre a "localização" de $P(x)$ ou em termos de quais valores x_i está distribuído

O nome valor esperado sugere que \bar{x} é o valor que esperamos obter num evento. No entanto devemos ser cientes disso com o que queremos dizer com isso

No caso de um dado de 6 faces com igual probabilidade para cada umas ($\frac{1}{6}$). O valor médio será

$$\bar{x} = \frac{1}{6}(1) + \frac{1}{6}(2) + \dots + \frac{1}{6}(6) = 3,5$$

Porem o valor 3,5 não é um evento possível; nunca iremos obser-lo em um lançamento. Neste sentido não é o valor que esperamos obter. A priori tampouco podemos esperar obter maius valores em torno de 3,5.

O significado de $\bar{x} = 3,5$ é que se lancarmos o dado N vezes e calcularmos o valor médio obtido (a média aritmética das N resultados) ele irá convergir para \bar{x} conforme $N \rightarrow \infty$ (isso é garantido pelo fato dos grandes números que discutimos depois). Assim num lançamento de N dados (ou após lançar N vezes o mesmo dado) esperamos obter \bar{x} como o valor esperado calculado e nesse sentido dizemos valor esperado. Outro exemplo é o caso de moedas, onde esperamos obter metade conos e metade caídos (valor esperado é "nulo"). Nesse caso quanto maior o número de lançamentos maior confiante podemos estar de que o número de conos será igual ao de caídos.

Note que estamos comparando o valor esperado técnico \bar{x} com o valor médio obtido em um número FINITO N de observações (por isso usar o nome valor esperado para \bar{x} técnico, e médio para o obtido em N eventos pode causar muita confusão. No entanto não garante manter este padrão).

Logo \bar{x} não é o valor esperado no sentido habitual. Num lançamento (ou evento aleatório) a melhor previsão que você pode fazer é usar o valor mais provável ($3,5$) e máximo. Como veremos em muitas coisas o valor médio é igual ao mais provável (o que ajuda a confusão)

Mencionamos que \bar{x} é a localização de $\hat{P}(x)$ já que os valores de x_i estão distribuídos ao redor de \bar{x} .

Podemos perguntar quão dispersos os pontos estão em relação a \bar{x} . Um modo de quantificá-lo isso seria obter

$$\overline{\Delta x} \equiv \overline{(x - \bar{x})} : \text{desvio médio}$$

Mos $\overline{(x - \bar{x})} = \bar{x} - \bar{x} = 0$ (a média da soma é a soma dos médios)

↳ das próprias definições da média temos desvios positivos e negativos que se cancelam.

Como estamos interessados somente na magnitude do desvio devemos obter

$|x - \bar{x}|$

Porém esta grandeza é matematicamente um pouco inconveniente por usar a função módulo.

Uma segunda opção é olhar para

$\overline{\Delta x^2} = \overline{(x - \bar{x})^2}$ chamada de desvio quadrático médio
 (ou dispersão ou variância ou segundo momento (em referência a \bar{x}))

$\overline{\Delta x^2}$ é uma ideia da dispersão
 Note que

- $\overline{\Delta x^2} \geq 0$ já que é uma soma de termos ≥ 0
- $\overline{\Delta x^2} = 0 \iff$ se e somente se $x_i = \bar{x} \ \forall i$

$$\bullet \quad \overline{\Delta x^2} = \overline{(x - \bar{x})^2} = \frac{(x^2 - 2\bar{x}x + \bar{x}^2)}{N} = \frac{\bar{x}^2 - 2\bar{x}\bar{x} + \bar{x}^2}{N} = \bar{x}^2 - \frac{2\bar{x}^2}{N}$$

$\overline{\Delta x^2}$ quantifica quanto disperso os pontos estão em referência a \bar{x} . Se ele for pequeno a maior parte dos pontos está perto da média. Assim podemos definir intervalos de confidêncio: um intervalo onde a maior parte dos pontos estão. Para a distribuição gaussiana (ou normal) por exemplo sabemos que $\approx 67\%$ dos "pontos" estão no intervalo $\bar{x} \pm \sqrt{\overline{\Delta x^2}}$.

Assim $\overline{\Delta x^2}$ é um valor esperado em 2 sentidos

1) Se obtivermos a média aritmética dos valores de $(x - \bar{x})^2$ numa amostra de N eventos, esperamos que tal valor converge para $\overline{\Delta x^2}$ no limite de $N \rightarrow \infty$.

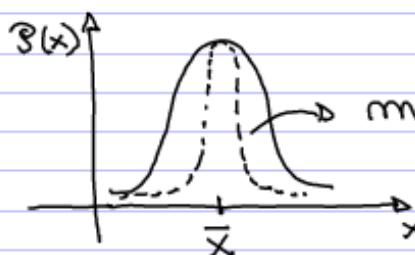
2) Esperamos encontrar uma fração dos pontos no intervalo $\bar{x} \pm \sqrt{\overline{\Delta x^2}}$ (a desigualdade de Chebysev quantifica isso: $P(|x - \bar{x}| \geq k\sigma_x) \leq 1/k^2$)

Logo pode-se usar $\overline{\Delta x^2}$ como uma estimativa do desvio médio em x . Na verdade devemos usar

$\sqrt{\Delta x^2} \rightarrow$ tem a mesma unidade de x

\rightarrow chamada de desvio padrão ($+b$ se usa a notação σ_x . b conhecido com RMS, root mean square, de Δx)

$\sqrt{\Delta x^2}$ mede a dispersão da distribuição



E' importante notar que tem mais significado físico olhar para o valor relativo do desvio

$\frac{\sqrt{\Delta x^2}}{\bar{x}} \rightarrow$ desvio padrão relativo

\rightarrow comparar $\sqrt{\Delta x^2}$ com \bar{x}

\rightarrow Isso porque o valor de $\sqrt{\Delta x^2}$ pode aumentar simplesmente porque o valor absoluto de \bar{x} aumentou

\rightarrow um desvio de 50 reais em 500 é "muito maior" que um desvio de 5000 em 500.000

Por completo, deve-se mencionar que tb se define os chamados n-ésimos momentos de $f(x)$

$$\bar{x^n} = \sum x_i^n$$

\rightarrow às vezes se usa $(x_i - \bar{x})^n$

E como dito anteriormente a média ou valor esperado é o primeiro momento:

Daí des todos os $\bar{x^n}$ podemos reconstruir (obter) a distribuição de prob. original

Por último, pode se definir valores esperados para uma função de x

$$\bar{f(x)} = \sum f(x_i) \bar{x}$$

E pode-se mostrar que (propriedades que já usamos acima)

$$i) \bar{f(x) + g(x)} = \bar{f(x)} + \bar{g(x)}$$

$$ii) \bar{c f(x)} = c \bar{f(x)}$$

Interpretações e Teoria de Informação

Essa definição que demos de probabilidade é empírica. Mas como já comentado há outros modos de obter a prob. de um evento.

A interpretação frequentista tem alguns "problemas".

- assume que os eventos tem a mesma prob., ou seja, assume prob. p/ definir a prob.
- assume que as freq. serão as mesmas num novo experimento no futuro
- não temos como saber quantas medidas são suficientes para uma estimativa

Note que podemos usar o argumento de simetria para dizer que a prob. dos eventos é igual: não temos, a priori, nenhuma razão para dizer que as prob. sejam diferentes.

Usamos o conceito de probabilidade e tempo todo no nosso dia a dia, quando tomamos decisões. Temos assim uma intuição sobre probabilidade. Probabilidade está relacionado com o nosso grau de confiança de que um evento irá ocorrer: a prob. é uma medida do grau de confiança que temos de que o evento irá ocorrer.

Nesse caso a prob. de um dado evento não depende do seu conhecimento prévio que temos. Por exemplo, se jogarmos uma moeda 100 vezes e obtermos 100 coros em seguida, podemos usar essa informação como evidência de que a moeda não é perfeita e portanto a prob. de obter outro coro é alta.

Outro exemplo. Eu e você jogamos cada um uma moeda. Qual a prob. de ter 2 coros? Se eu sei que minha moeda é coroa, vou dizer que a prob. é zero. Se não conheço os resultados de nenhuma das duas moedas irei dizer que a prob. é $\frac{1}{4}$. Se sei que minha moeda é coroa, então direi que a prob. é $\frac{1}{2}$.

Assim sempre "calculamos" uma probabilidade condicional: prob. do evento E dado a informação I (o PCEI)

Pessoas racionais com a mesma informação devem chegar a mesma conclusão sobre a prob. de um evento. Essa ideia é chamada de um "aposta coerente".

A aposta coerente deve ser considerada virtual. Uma pessoa pode considerar um evento 99,999%, provável e ainda se recusar a apostar R\$ 1.000.000,00 contra R\$ 1,00 se R\$ 1.000.000,00 for muito mais dinheiro do que ela tem. Mas poderíamos convidar essa pessoa que essa aposta seria justa se ela tivesse uma quantidade infinita de dinheiro.

Ou seja, decisões dependem não só da prob. como um grau de confiança de que um evento irá ocorrer, mas tb na importância subjetiva das consequências (neste caso a quantidade de dinheiro)

↳ estimativas de prob. devem ser separadas de outros questões subjetivas envolvidas no conseq. do evento.

Nessa interpretação, prob. estão diretamente relacionados com o conceito de informação. Considere dois experimentos codificados com resultados E_1, E_2 com prob. P_1, P_2 : para um moedas, por exemplo:

- No primeiro experimento temos $P_1 = P_2 = 1/2$ (moeda perfeita)
- No segundo experimento temos $P_1 = 1/5$ e $P_2 = 4/5$ (moeda viciada)

Nossa intuição diria que o primeiro experimento é mais incerto que o segundo (não?)

Consideremos outros 2 experimentos. No primeiro há quatro possíveis resultados com $P_1 = P_2 = P_3 = P_4 = \frac{1}{4}$ e no segundo há seis possíveis resultados com $P_1 = P_2 = P_3 = P_4 = P_5 = P_6$. Apesar de que em ambos os casos os resultados são equiprováveis, diríamos que o segundo experimento é mais incerto que o terceiro, já que não é mais possível dizer.

Podemos tornar essa intuição mais "precisa" introduzindo uma medida de incerteza que seja consistente com nossa intuição.

Queremos definir uma função da distribuição de prob. que meça quanto incerto há: $S(P_1, P_2, \dots, P_i, \dots)$

No caso onde os eventos são equiprováveis, $P_1 = P_2 = \dots = P_i = \frac{1}{n}$ com $n = \#$ total de possíveis resultados, temos $S(\frac{1}{n}, \dots, \frac{1}{n}) \propto \text{similares } S(n)$

Nesse caso $S(n)$ tem que satisfazer algumas condições simples

$$1) S(L=1) = 0 \quad \text{se há uma possibilidade só há incerteza}$$

$$2) S(L_1) > S(L_2) \quad \text{se } L_1 > L_2 \rightarrow S(n) \text{ aumenta monotonicamente com } n$$

No caso de múltiplos eventos: pegar um dado com L_1 possíveis resultados, e outro mendo com L_2 possíveis resultados; todos equiprováveis. O número total de possíveis resultados é $L = L_1 L_2$. Se o resultado do dado é conhecido a incerteza em relação a ele é zero mas ainda há incerteza associada a mendo. Assim devemos ter

$$3) S(L_1 L_2) = S(L_1) + S(L_2) \quad (\text{Additividade})$$

Pode-se mostrar que há um único função que satisfaça a essas propriedades (ver Cap. 3 de Hume Fould). Ela tem a forma

$$S(x) = A \ln x + B$$

B deve ser nulo p/ satisfazer a condição 1) e A é arbitrária e assim estaremos $A=1$.

Logo p/ prob. iguais temos,

$$S(n) = \ln n$$

No caso onde os prob. não são iguais tb pode-se encontrar a função que satisfaça as propriedades acima. Nesse caso tem-se

$$S = - \sum_i p_i \ln p_i \rightarrow \text{se reduz a } \ln L \text{ para } p_i = \frac{1}{L}$$

Pode-se ver que se um dos resultados é certo $p_i = 1 \Rightarrow p_j = 0 \forall j \neq i$ então $S = -1 \ln 1 = 0$

Pode-se mostrar tb que o caso $p_i = \frac{1}{L}$, prob. igual, maximiza a função S . Assim pode-se usar um "princípio da máxima incerteza ou ignorância" para justificar o fato dos prob. iguais a priori

A expressão para S foi proposta Claude Shannon em 1949 nos seus trabalhos sobre Teoria Estatística de Comunicações. Shannon define a informação i_e trazida por um evento com prob. P_e como

$$i_e = -K \ln P_e$$

Aqui uma informação constitui um ou mais eventos ocorridos em relação a um conjunto finito de eventos possíveis. Uma informação é mais importante quanto menor for a prob. de ocorrer (como no exemplo dos dois experimentos acima).

Se o evento ainda não ocorreu a possibilidade que o sistema traga informações correspondente ao evento é o produto da informação que ele tem caso ocorra é a prob. de ocorrer efetivamente:

$$I_e = -K P_e \ln P_e$$

Considerando todos os eventos possíveis no sistema a possibilidade que o sistema leve informação ao exterior se pudesse distinguir cada um dos eventos possíveis é

$$-K \sum_e P_e \ln P_e$$

Antes de observar os eventos, podemos considerar que a expressão acima (a menor de uma constante) representa a falta de informações, ou nesse grau de ignorância, sobre o sistema. Assim a expressão acima é quanto obtemos de informações, em média, quando observamos um evento. Ao observar um dado evento é, nesse grau de ignorância díminha, e devemos excluir este evento do sigma acima.