

Probabilidade discreta

Mário S. Alvim
(msalvim@dcc.ufmg.br)

Quantitative Information Flow

DCC-UFMG
(2021/1)

Teoria de probabilidade: Introdução

- A **Teoria de Probabilidade** nasceu junto com a Análise Combinatória, ambas aplicadas ao estudo dos jogos de azar.
- A Teoria de Probabilidade é hoje fundamental em diversas áreas, incluindo:
 - (a) estatística e estudo de fenômenos complexos,
 - (b) aprendizado de máquina,
 - (c) inteligência artificial,
 - (d) física (termodinâmica, quântica),
 - (e) algoritmos probabilísticos,
 - (f) protocolos seguros,
 - (g) teoria da informação,
 - (h) ...
- Aqui nos concentraremos na **Teoria de Probabilidade Discreta**, que lida com **conjuntos enumeráveis**.

Introdução

- A **probabilidade discreta** lida apenas com conjuntos enumeráveis.
- Um conjunto é um **conjunto enumerável** se
 1. ele é finito,
ou
 2. existe uma bijeção entre seus elementos e o conjunto dos números naturais \mathbb{N} .
- Um conjunto é enumerável se é possível enumerar seus elementos, ou seja, se é possível produzir uma lista (possivelmente infinita) que contenha todos seus elementos.

Por exemplo:

- (a) São conjuntos enumeráveis: os naturais \mathbb{N} , os inteiros \mathbb{Z} e os racionais \mathbb{Q} .
- (b) São conjuntos não-enumeráveis: os reais \mathbb{R} e qualquer intervalo contínuo de \mathbb{R} .

- Um **experimento** ou **ensaio** é um procedimento que produz um resultado dentre vários resultados possíveis.
- O **espaço amostral** de um experimento é o conjunto de todos os resultados possíveis para o experimento.
- Um **evento** é um subconjunto do espaço amostral.
- A definição de Laplace para probabilidade é como se segue.

Seja S um espaço amostral finito de resultados igualmente prováveis, e seja $E \subseteq S$ um evento.

A **probabilidade (de Laplace) do evento** E é dada por

$$p(E) = \frac{|E|}{|S|}.$$

Ou seja, a probabilidade de um evento E é a razão entre o número de resultados que satisfazem E e o total de resultados possíveis.

- **Exemplo 1:** Uma urna contém 5 bolas vermelhas e 3 bolas azuis. Qual a probabilidade de uma bola retirada aleatoriamente da urna ser azul?

Solução: O experimento consiste em retirar uma bola da urna.

O espaço amostral S do experimento é o conjunto de todos os resultados possíveis, ou seja, um conjunto de 8 elementos (um para cada bola que pode ser retirada da urna).

Estamos interessados no evento E em que uma bola azul é retirada. Este evento corresponde ao subconjunto de S contendo todas as bolas azuis, e E possui 3 elementos.

Pela definição de Laplace, se todos os resultados do espaço amostral são igualmente prováveis, a probabilidade de E é dada por

$$P(E) = \frac{|E|}{|S|} = \frac{3}{8}.$$

- **Exemplo 2:** Quando um dado de seis faces é rolado, qual a probabilidade de se obter a face 5 voltada para cima?

Solução: O experimento consiste em jogar rolar um dado de seis faces.

O espaço amostral S do experimento é o conjunto de todas as faces do dado que podem estar voltadas para cima, ou seja, o espaço amostral é o conjunto $S = \{1, 2, 3, 4, 5, 6\}$.

Estamos interessados no evento $E = \{5\}$ correspondendo à face 5 cair voltada para cima.

Pela definição de Laplace, se todos os resultados do espaço amostral são igualmente prováveis, a probabilidade de E é dada por

$$P(E) = \frac{|E|}{|S|} = \frac{|\{5\}|}{|\{1, 2, 3, 4, 5, 6\}|} = \frac{1}{6}.$$



- **Exemplo 3:** Quando dois dados de seis faces são rolados, qual a probabilidade da soma dos números de cada dado ser 7?

Solução: O experimento consiste em rolar dois dados de seis faces.

O espaço amostral S do experimento é o conjunto de todos os pares de dois números possíveis, sendo cada número do par o resultado de um dos dados.

Como há 6 possibilidades para o resultado de cada dado, pela regra do produto o espaço amostral tem $6 \cdot 6 = 36$ possibilidades no total.

Estamos interessados no evento E em que a soma dos números em cada dado é 7. Ou seja, $E = \{(1, 6), (2, 5), (3, 4), (4, 3), (5, 2), (6, 1)\}$.

Pela definição de Laplace, se todos os resultados do espaço amostral são igualmente prováveis, a probabilidade de E é dada por

$$P(E) = \frac{|E|}{|S|} = \frac{6}{36} = \frac{1}{6}.$$



- **Exemplo 4:** Na Mega Sena, 6 dezenas são sorteadas aleatoriamente de um conjunto de dezenas de 01 a 60, e uma aposta é premiada se ela contiver as 6 dezenas sorteadas.

Qual a probabilidade de uma aposta de 6 dezenas ser premiada?

Solução: O experimento consiste em sortear 6 dezenas dentre 60.

O espaço amostral S do experimento é o conjunto de todas combinações de 6 dezenas de um conjunto de 60, ou seja,

$$|S| = C(60, 6) = \frac{60!}{6!(60 - 6)!} = 50\,063\,860.$$

Estamos interessados no evento E em que o sorteio coincide com uma aposta específica de 6 dezenas.

Se todos os resultados do espaço amostral são igualmente prováveis, temos

$$P(E) = \frac{|E|}{|S|} = \frac{1}{50\,063\,860} \approx 0.00000002.$$

- **Exemplo 5:** Qual a probabilidade de que uma mão de Pôquer de 5 cartas seja um *full house*, ou seja, 3 cartas de um mesmo tipo e 2 cartas de um outro tipo?

(Lembre-se de que num baralho normal há 52 cartas divididas em 4 naipes (copas, espadas, ouros e paus), e cada naipe contém uma carta de cada um dos 13 tipos existentes (ás, valete, dama, rei, ou um número entre 2 e 10).)

Solução: O experimento consiste em retirar 5 cartas de um conjunto de 52 cartas do baralho.

O espaço amostral S do experimento é o conjunto de todas combinações de 5 cartas retiradas de um conjunto de 52, ou seja,

$$|S| = C(52, 5) = \frac{52!}{5!(52 - 5)!} = 2\,598\,960.$$

- Exemplo 5: (Continuação)

Estamos interessados no evento E em que a mão consiste em um *full house*.

Para contar quantos resultados do experimento são um *full house*, note que um *full house* pode ser obtido através das seguintes etapas consecutivas:

1. Escolhem-se os 2 tipos de cartas dentre os 13 possíveis. Já que a ordem dos tipos importa (2 rainhas e 3 azes é diferente de 3 rainhas e 2 azes), há $P(13, 2) = 13!/(13 - 2)! = 156$ maneiras de se fazer isto.
2. Escolhem-se 3 naipes do primeiro tipo entre os 4 possíveis. Há $C(4, 3) = 4!/(3!(4 - 3)!) = 4$ maneiras de se fazer isto.
3. Escolhem-se 2 naipes do segundo tipo entre os 4 possíveis. Há $C(4, 2) = 4!/(2!(4 - 2)!) = 6$ maneiras de se fazer isto.

Logo, pela regra da multiplicação, o número total de maneiras de se obter um *full house* é

$$P(13, 2) \cdot C(4, 3) \cdot C(4, 2) = 3744.$$

- Exemplo 5: (Continuação)

Assim, pela definição de Laplace, se todos os resultados do espaço amostral são igualmente prováveis, a probabilidade de E é dada por

$$P(E) = \frac{|E|}{|S|} = \frac{3744}{2598960} \approx 0.0014.$$



- Segundo a definição de Laplace, um evento nada mais é que um subconjunto do espaço amostral.
- Portanto, é natural que a probabilidade da combinação de eventos possa ser calculada utilizando operações sobre conjuntos (união, interseção, complemento, etc.).

Probabilidade finita: Combinação de eventos

- O seguinte resultado associa a probabilidade de um evento à probabilidade de seu evento complementar.
- **Teorema:** Seja E um evento de um espaço amostral S . A probabilidade do evento \bar{E} , o complemento do evento E , é dada por

$$p(\bar{E}) = 1 - p(E).$$

Prova. Note que $|\bar{E}| = |S| - |E|$. Logo

$$p(\bar{E}) = \frac{|\bar{E}|}{|S|} = \frac{|S| - |E|}{|S|} = 1 - \frac{|E|}{|S|} = 1 - p(E). \square$$

- **Corolário:** Se E é um evento num espaço amostral S , então

$$p(E) + p(\bar{E}) = 1.$$

- Exemplo 6: Uma sequência de 10 bits é aleatoriamente gerada.

Qual a probabilidade de ao menos um dos bits ser 0?

Solução: O espaço amostral S consiste no conjunto de todas as strings de 10 bits, logo $|S| = 2^{10} = 1\,024$.

Estamos interessados no evento E em que ao menos um bit da string é 0.

O evento oposto, \bar{E} , é aquele em que nenhum bit da string é 0. Como só há uma string sem bits 0 (a string em que todos os bits são 1), temos que $|\bar{E}| = 1$.

Logo, podemos calcular $P(E)$ como

$$P(E) = 1 - P(\bar{E}) = 1 - \frac{|\bar{E}|}{|S|} = 1 - \frac{1}{1\,024} = \frac{1\,023}{1\,024}.$$



Probabilidade finita: Combinação de eventos

- O seguinte resultado associa a probabilidade da união de eventos às probabilidades de seus componentes.
- **Teorema:** Sejam E_1 e E_2 eventos de um espaço amostral S . Então

$$p(E_1 \cup E_2) = p(E_1) + p(E_2) - p(E_1 \cap E_2).$$

Prova. Pelo princípio da inclusão-exclusão de conjuntos,

$$|E_1 \cup E_2| = |E_1| + |E_2| - |E_1 \cap E_2|.$$

Logo

$$\begin{aligned} p(E_1 \cup E_2) &= \frac{|E_1 \cup E_2|}{|S|} \\ &= \frac{|E_1| + |E_2| - |E_1 \cap E_2|}{|S|} \\ &= \frac{|E_1|}{|S|} + \frac{|E_2|}{|S|} - \frac{|E_1 \cap E_2|}{|S|} \\ &= p(E_1) + p(E_2) - p(E_1 \cap E_2). \square \end{aligned}$$

- **Exemplo 7:** Qual a probabilidade de um inteiro selecionado aleatoriamente entre os 100 primeiros inteiros ser divisível por 2 ou por 5?

Solução: O espaço amostral S consiste no conjunto dos inteiros positivos menores ou iguais a 100, logo $|S| = 100$.

Estamos interessados no evento E em que um inteiro é divisível por 2 ou por 5.

Podemos escrever $E = E_1 \cup E_2$, onde E_1 representa o evento em que o número é divisível por 2, e E_2 representa o evento em que o número é divisível por 5.

É fácil calcular que

- $|E_1| = 50$ (pois há 50 números divisíveis por 2 no intervalo), e
- $|E_2| = 20$ (pois há 20 números divisíveis por 5 no intervalo).

- Exemplo 7: (Continuação)

Note que, nesse caso, $E_1 \cap E_2$ representa o evento em que o número é divisível por 2 e por 5 ao mesmo tempo, ou seja, o evento em que o número é divisível por 10.

É fácil calcular que

- $|E_1 \cap E_2| = 10$ (pois há 10 números divisíveis por 10 no intervalo).

Logo, podemos calcular $P(E)$ como

$$\begin{aligned}P(E) &= P(E_1 \cup E_2) \\&= P(E_1) + P(E_2) - P(E_1 \cap E_2) \\&= \frac{50}{100} + \frac{20}{100} - \frac{10}{100} \\&= \frac{3}{5}.\end{aligned}$$



Teoria de probabilidades

- Anteriormente definimos a probabilidade de um evento E em um espaço amostral S como Laplace fez, ou seja, como

$$P(E) = \frac{|E|}{|S|}.$$

Esta definição de probabilidade assume que os resultados de um experimento são todos igualmente prováveis.

(Além disso, ela só funciona quando o espaço amostral é finito.)

- Nesta seção vamos estudar como definir probabilidades em situações em que os resultados de um evento não são todos igualmente prováveis.
- Além disso, vamos estudar como as probabilidades de eventos se relacionam através de **condicionamento** e **independência**, e vamos introduzir o conceito de **variáveis aleatórias**.

Atribuindo probabilidades

- Seja S o espaço amostral de um experimento, tal que S é um conjunto enumerável.

Podemos associar uma probabilidade $p(s)$ para cada resultado $s \in S$, desde que as seguintes condições sejam satisfeitas:

1. a probabilidade de qualquer resultado é um real não-negativo não maior que 1:

$$0 \leq p(s) \leq 1 \quad \text{para todo } s \in S;$$

2. com certeza um dentre os resultados deve ocorrer:

$$\sum_{s \in S} p(s) = 1.$$

- Podemos ver p como uma função que mapeia elementos do espaço amostral para os reais no intervalo $[0, 1]$.

Chamamos tal função de **distribuição de probabilidade**.

- A atribuição de probabilidades aos resultados de um experimento é normalmente feita segundo a **interpretação frequentista de probabilidade**.
- Segundo a interpretação frequentista, a probabilidade $p(s)$ associada a um resultado s do espaço amostral deve refletir a frequência com que o resultado s é esperado em relação o total de resultados possíveis para o experimento.

Mais formalmente, $p(s)$ deve ser igual ao limite do número de vezes que o resultado s acontece, dividido pelo número de vezes que o experimento é realizado, quando o número de experimentos tende a infinito.

- Existem outras interpretações para probabilidades (e.g., Bayesiana), que estudaremos mais adiante no curso.

- Seja S um conjunto de n elementos.

A **distribuição uniforme de probabilidade** atribui probabilidade $1/n$ para cada elemento de S .

- **Exemplo 8:** Um dado justo (não-viciado) de 6 faces é rolado.

Qual a distribuição probabilidade devemos atribuir aos possíveis resultados do experimento?

Solução: Os resultados possíveis do experimento de se rolar um dado de 6 faces são dados pelo espaço amostral $S = \{1, 2, 3, 4, 5, 6\}$.

Se o dado não está viciado, espera-se que, se rolarmos o dado infinitas vezes, obtenhamos cada uma das face em $1/6$ das vezes.

Logo, atribuímos a distribuição de probabilidade uniforme aos resultados do experimento:

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



- **Exemplo 9:** Um dado viciado de 6 faces é rolado. Neste dado, a probabilidade da face de número 3 cair para cima é o dobro da probabilidade de qualquer outra face cair para cima.

Qual a distribuição probabilidade devemos atribuir aos possíveis resultados do experimento?

Solução: Os resultados possíveis do experimento de se rolar um dado de 6 faces são dados pelo espaço amostral $S = \{1, 2, 3, 4, 5, 6\}$.

Para se atribuir probabilidade a cada um dos resultados possíveis, notamos que a face 3 ocorre com o dobro da frequência que qualquer outra face, ou seja:

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

Atribuindo probabilidades

- Exemplo 9: (Continuação)

Como a distribuição de probabilidade deve satisfazer

$$\sum_{s \in S} p(s) = 1,$$

temos que

$$p(1) + p(2) + p(3) + p(4) + p(5) + p(6) = 1,$$

o que implica que

$$\frac{1}{2}p(3) + \frac{1}{2}p(3) + p(3) + \frac{1}{2}p(3) + \frac{1}{2}p(3) + \frac{1}{2}p(3) = 1,$$

de onde concluímos que $p(3) = 2/7$, e a distribuição deve ser

$$p(3) = \frac{2}{7} \quad \text{e} \quad p(1) = p(2) = p(4) = p(5) = p(6) = \frac{1}{7}.$$



- Vimos como atribuir probabilidade a cada resultado do espaço amostral de um experimento.

Falta estender a noção de probabilidade para eventos, que são subconjuntos do espaço amostral.

- A **probabilidade de um evento** E é a soma das probabilidades dos resultados em E :

$$p(E) = \sum_{s \in E} p(s).$$

- Exemplo 10: Qual a probabilidade de obtermos um número par ao rolar um dado de 6 faces não-viciado?

Solução: Se atribuímos a distribuição de probabilidade uniforme ao espaço amostral do experimento obtemos:

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

Estamos interessados no evento $E = \{2, 4, 6\}$, ou seja, o evento de um número par ser obtido no lançamento do dado.

A probabilidade deste evento é dada por:

$$p(\{2, 4, 6\}) = p(2) + p(4) + p(6) = \frac{1}{6} + \frac{1}{6} + \frac{1}{6} = \frac{1}{2}.$$



Atribuindo probabilidades

- **Exemplo 11:** Um dado viciado de 6 faces é rolado. Neste dado, a probabilidade da face de número 3 cair para cima é o dobro da probabilidade de qualquer outra face cair para cima.

Qual a probabilidade de obtermos um número primo no lançamento deste dado?

Solução: Em um exemplo anterior atribuímos a seguinte distribuição de probabilidade ao espaço amostral do experimento:

$$p(3) = \frac{2}{7} \quad \text{e} \quad p(1) = p(2) = p(4) = p(5) = p(6) = \frac{1}{7}.$$

Estamos interessados no evento $E = \{2, 3, 5\}$, ou seja, o evento de um número primo ser obtido no lançamento do dado (1 não é um número primo!).

A probabilidade deste evento é dada por:

$$p(\{2, 3, 5\}) = p(2) + p(3) + p(5) = \frac{1}{7} + \frac{2}{7} + \frac{1}{7} = \frac{4}{7}.$$



- Uma vez definida a probabilidade de um evento, podemos definir a probabilidade da combinação de eventos.

Como eventos são subconjuntos do espaço amostral, é natural que a probabilidade da combinação de eventos seja definida em termos de operações sobre conjuntos (união, interseção, complemento, etc.)

- Como veremos, as definições de Laplace ainda são válidas para a combinação de eventos.

Combinação de eventos

- **Teorema:** Seja E um evento de um espaço amostral S . A probabilidade do evento \bar{E} , o complemento do evento E , é dada por

$$p(\bar{E}) = 1 - p(E)$$

Prova. Sabemos que

$$\sum_{s \in S} p(s) = 1.$$

Como cada resultado $s \in S$ ou pertence a E ou pertence a \bar{E} , temos que

$$\sum_{s \in E} p(s) + \sum_{s \in \bar{E}} p(s) = 1 \quad \Rightarrow \quad p(E) + p(\bar{E}) = 1,$$

de onde concluímos que

$$p(E) = 1 - p(\bar{E}).$$



- **Teorema:** Sejam E_1 e E_2 eventos de um espaço amostral S . A probabilidade do evento $E_1 \cup E_2$ é dada por

$$p(E_1 \cup E_2) = p(E_1) + p(E_2) - p(E_1 \cap E_2)$$

Prova. Para calcular $p(E_1 \cup E_2)$ devemos somar $p(s)$ para todo $s \in E_1 \cup E_2$.

Mas sabemos que cada elemento $s \in E_1 \cup E_2$ satisfaz exatamente uma das seguintes propriedades:

1. $s \in E_1$ e $s \notin E_2$,
2. $s \notin E_1$ e $s \in E_2$, ou
3. $s \in E_1$ e $s \in E_2$.

Logo, para calcular $p(E_1 \cup E_2)$ podemos somar $p(E_1) + p(E_2)$, e depois subtrair do resultado $p(E_1 \cap E_2)$, uma vez que os elementos da interseção de E_1 e E_2 foram contados duas vezes. □

- **Teorema:** Sejam E_1, E_2, \dots uma sequência de eventos mutuamente disjuntos em um espaço amostral S . Então

$$p\left(\bigcup_i E_i\right) = \sum_i p(E_i).$$

(Note que o teorema é válido quando E_1, E_2, \dots consiste em um número contável de eventos, mesmo que infinito.)

Prova. Exercício para o aluno!

Probabilidade condicional

- Muitas vezes estamos interessados na probabilidade de um evento E ocorrer dado que um outro evento F já ocorreu.

Por exemplo, podemos estar interessados na:

- (a) probabilidade de uma criança nascer daltônica dado que ela é do sexo feminino (o que faz sentido visto que daltonismo ocorre com frequências diferentes em cada sexo), ou
- (b) probabilidade de um aluno ser aprovado em Teoria da Informação dado que ele não fez as listas de exercícios (o que é com certeza uma probabilidade bem baixa!).

A isto chamamos de **probabilidade condicional** do evento E dado o evento F .

- **A probabilidade condicional de E dado F** , denotada por $p(E | F)$, é definida como

$$p(E | F) = \frac{p(E \cap F)}{p(F)}.$$

- Exemplo 12: Um dado não-viciado de 20 faces (*RPG, alguém?*) é rolado. Qual a probabilidade de obtermos um resultado divisível por 3 dado que obtivemos um número par?

Solução: O espaço amostral do experimento é $S = \{1, 2, 3, \dots, 20\}$.

Sejam E o evento de o resultado ser um número divisível por 3 e F o evento de o resultado ser um número par.

Devemos calcular

$$p(E | F) = \frac{p(E \cap F)}{p(F)}.$$

- Exemplo 12: (Continuação)

Note que

- $F = \{2, 4, 6, 8, 10, 12, 14, 16, 18, 20\}$ (os resultados pares), e
- $E \cap F = \{6, 12, 18\}$ (os resultados ao mesmo tempo pares e divisíveis por 3).

Como o dado é não-viciado, a distribuição sobre resultados é uniforme e portanto

$$p(F) = 10/20 = 1/2 \quad \text{e}$$
$$p(E \cap F) = 3/20.$$

Logo

$$p(E | F) = \frac{3/20}{1/2} = \frac{3}{10}.$$



- Exemplo 13: Qual a probabilidade de um casal com dois filhos ter dois garotos, dado que o casal tem ao menos um garoto?

Assuma que a probabilidade de se ter um garoto ou uma garota é uniforme, ou seja, que $p(BB) = p(BG) = p(GB) = p(GG) = 1/4$, onde B representa um garoto (*boy*) e G representa uma garota (*girl*), e o espaço amostral do experimento é dado por $S = \{BB, BG, GB, GG\}$.

Solução: Seja E o evento de o casal ter dois garotos, e seja F o evento de o casal ter ao menos um garoto.

Devemos calcular

$$p(E | F) = \frac{p(E \cap F)}{p(F)}.$$

Note que $F = \{BB, BG, GB\}$ e $E \cap F = \{BB\}$.

- Exemplo 13: (Continuação)

Uma vez que a probabilidade é uniforme, temos que $p(F) = 3/4$ e $p(E \cap F) = 1/4$.

Logo

$$p(E | F) = \frac{p(E \cap F)}{p(F)} = \frac{1/4}{3/4} = \frac{1}{3}.$$



Independência

- Intuitivamente, dois eventos são independentes se a ocorrência de um não altera a probabilidade da ocorrência do outro.
- Formalmente, E e F são **eventos independentes** se a probabilidade de E dado F for igual à probabilidade de E :

$$p(E | F) = p(E).$$

- Note que pela definição de probabilidade condicional, $p(E | F) = p(E \cap F)/p(F)$, e podemos escrever $p(E \cap F) = p(F)p(E | F)$. Mas quando E e F são independentes, $p(E | F) = p(E)$ e podemos escrever $p(E \cap F) = p(E)p(F)$.

Esta observação leva à seguinte definição alternativa de independência.

E e F são **eventos independentes** se, e somente se,

$$p(E \cap F) = p(E)p(F).$$

- Exemplo 14: Um dado não-viciado de 20 faces é rolado.

Seja E o evento em que obtemos um resultado divisível por 3, e seja F o evento em que obtemos um número par.

Os eventos E e F são independentes?

Solução: E e F são independentes se, e somente se, $p(E \cap F) = p(E)p(F)$. Sabemos que:

- $E = \{3, 6, 9, 12, 15, 18\}$ é o evento de obtermos um número divisível por 3, e como o dado é justo $p(E) = 6/20 = 3/10$,
- $F = \{2, 4, 6, 8, 10, 12, 14, 16, 18\}$ é o evento de obtermos um número par, e como o dado é justo $p(F) = 10/20 = 1/2$, e
- $E \cap F = \{6, 12, 18\}$ é o evento de obtermos um número par e divisível por 3, e como o dado é justo $p(E \cap F) = 3/20$.

Agora verificamos que $p(E \cap F) = 3/20$ e $p(E)p(F) = 3/10 \cdot 1/2 = 3/20$ são iguais, logo os eventos são independentes. \triangleleft

- Exemplo 15: Um casal tem dois filhos.

Assuma que a probabilidade de se ter um garoto ou uma garota é uniforme, ou seja, que $p(BB) = p(BG) = p(GB) = p(GG) = 1/4$ onde B representa um garoto (*boy*) e G representa uma garota (*girl*), e o espaço amostral do experimento é dado por $S = \{BB, BG, GB, GG\}$.

Seja E o evento de o casal ter dois garotos, e seja F o evento de o casal ter ao menos um garoto.

Os eventos E e F são independentes?

- Exemplo 15: (Continuação)

Solução: E e F são independentes se, e somente se, $p(E \cap F) = p(E)p(F)$. Sabemos que:

- $E = \{BB\}$ é o evento de o casal ter dois garotos, e $p(E) = 1/4$,
- $F = \{BB, BG, GB\}$ é o evento de o casal ter ao menos um garoto, e $p(F) = 3/4$, e
- $E \cap F = \{BB\}$ é o evento de o casal ter pelo menos um garoto e, ao mesmo tempo, ter dois garotos, e $p(E \cap F) = 1/4$.

Agora verificamos que $p(E \cap F) = 1/4$ e $p(E)p(F) = 1/4 \cdot 3/4 = 3/16$ não são iguais, logo os eventos não são independentes.



Ensaio de Bernoulli e a distribuição binomial

- Suponha que um experimento tenha apenas dois resultados possíveis.

Por exemplo:

(a) um bit gerado aleatoriamente, (b) o lançamento de uma moeda.

- Cada realização do experimento é chamada de um **ensaio de Bernoulli**.

Os resultados possíveis do experimento são normalmente chamados de **sucesso** e **fracasso**.

Se a probabilidade de sucesso em um ensaio de Bernoulli é p , a probabilidade de fracasso é $(1 - p)$.

- Muitos problemas podem ser resolvidos determinando-se a probabilidade de ocorrerem k sucessos em um experimento consistindo em n ensaios de Bernoulli mutuamente independentes.

(Ensaio de Bernoulli são mutuamente independentes se a probabilidade de sucesso em cada ensaio mantém-se constante e igual a p .)

Ensaio de Bernoulli e a distribuição binomial

- Ensaio de Bernoulli dão origem a um tipo de distribuição muito particular, chamado de distribuição binomial.

O próximo exemplo motiva tal distribuição.

- **Exemplo 16:** Uma moeda viciada produz como resultado cara com probabilidade $3/4$ e coroa com probabilidade $1/4$.

Se lançarmos a moeda 10 vezes, qual a probabilidade de obtermos exatamente 3 caras?

Solução: O espaço amostral do experimento é o conjunto S de todos os resultados possíveis para 10 lançamentos das moedas, ou seja, $|S| = 2^{10} = 1\,024$.

Estamos interessados no evento E em que exatamente 3 destes lançamentos resultem em caras.

É fácil ver que $|E| = C(10, 3)$.

- Exemplo 16: (Continuação)

Cada lançamento é independente dos demais, logo a probabilidade de cada resultado em E é

$$\left(\frac{3}{4}\right)^3 \left(\frac{1}{4}\right)^7,$$

pois caras ocorrem 3 vezes com probabilidade $3/4$ cada, e coroas ocorrem $10 - 3 = 7$ vezes com probabilidade $1/4$ cada.

A probabilidade do evento E é a soma das probabilidades de cada um de seus resultados, e como há $C(10, 3)$ resultados em E :

$$p(E) = C(10, 3) \left(\frac{3}{4}\right)^3 \left(\frac{1}{4}\right)^7 = 120 \cdot \frac{27}{16\,384} = \frac{3\,240}{16\,384}.$$



Ensaio de Bernoulli e a distribuição binomial

- **Teorema:** A probabilidade de k sucessos em n ensaios de Bernoulli independentes, cada ensaio com probabilidade de sucesso p e de fracasso $(1 - p)$, é

$$C(n, k)p^k(1 - p)^{n-k}.$$

Prova. O resultado de n ensaios de Bernoulli é uma n -tupla (t_1, t_2, \dots, t_n) , onde $t_i = S$ (sucesso) ou $t_i = F$ (fracasso) para cada $i = 1, 2, \dots, n$.

Uma vez que os n ensaios são independentes, a probabilidade de um resultado consistir em k sucessos e $n - k$ falhas (em qualquer ordem) é $p^k(1 - p)^{n-k}$.

Como há $C(n, k)$ n -tuplas contendo exatamente k sucessos (e, consequentemente, $n - k$ fracassos), a probabilidade de k sucessos é

$$C(n, k)p^k(1 - p)^{n-k}.$$



- Chamamos a distribuição gerada por ensaios de Bernoulli de **distribuição binomial**.

- Muitos problemas estão interessados em um valor numérico associado ao resultado de um experimento.

Porém, nem todo espaço amostral é constituído por números.

- Uma **variável aleatória** é uma função do espaço amostral de um experimento para o conjunto dos números reais.

Em outras palavras, uma variável aleatória associa um número real a cada resultado possível do experimento.

- Exemplo 17: Suponha que uma moeda seja lançada três vezes.

Seja $X(s)$ a variável aleatória que mapeia o resultado s do experimento para o número de caras em s .

Chamando H de cara (*heads*) e T de coroa (*tails*), o espaço amostral do experimento é $S = \{HHH, HHT, HTH, HTT, THH, THT, TTH, TTT\}$.

A variável aleatória $X(s)$ então assume os valores

$$X(HHH) = 3,$$

$$X(HHT) = X(HTH) = X(THH) = 2,$$

$$X(TTH) = X(THT) = X(HTT) = 1,$$

$$X(TTT) = 0.$$

e



Variáveis aleatórias

- Exemplo 18: Suponha que uma moeda seja lançada três vezes.

Seja $Y(s)$ a variável aleatória que mapeia o resultado s do experimento para 1 se o último resultado obtido em s foi cara, e para 0 em caso contrário.

Seja $Z(s)$ a variável aleatória que mapeia o resultado s do experimento para o número de coroas obtidas nos dois primeiros lançamentos em s .

Chamando H de cara (*heads*) e T de coroa (*tails*), o espaço amostral do experimento é $S = \{HHH, HHT, HTH, HTT, THH, THT, TTH, TTT\}$.

A variável aleatória $Y(s)$ então assume os valores

$$\begin{aligned} Y(HHH) = Y(HTH) = Y(THH) = Y(TTH) &= 1, & e \\ Y(HHT) = Y(HTT) = Y(THT) = Y(TTT) &= 0, \end{aligned}$$

e a variável aleatória $Z(s)$ então assume os valores

$$\begin{aligned} Z(HHH) = Z(HHT) &= 0, \\ Z(HTH) = Z(HTT) = Z(THH) = Z(THT) &= 1, & e \\ Z(TTH) = Z(TTT) &= 2. \end{aligned}$$

- A importância da nomenclatura:
 - variáveis aleatórias não são variáveis, são funções,
 - variáveis aleatórias não são aleatórias!
- O que muitas vezes queremos dizer quando nos referimos a “variável aleatória” é a distribuição de probabilidade sobre os valores que a variável aleatória pode assumir.
- A **distribuição de uma variável aleatória** X em um espaço amostral S é o conjunto de pares

$$(r, p(X = r)),$$

para todo $r \in X(S)$, onde $p(X = r)$ é a probabilidade de X assumir o valor r .

Uma distribuição é usualmente descrita especificando-se $p(X = r)$ para cada $r \in X(S)$.

- Exemplo 19: Suponha que uma moeda não-viciada seja lançada três vezes.

Seja $X(s)$ a variável aleatória que mapeia o resultado s do experimento para o número de caras em s .

Qual a distribuição da variável aleatória X ?

Solução: A variável aleatória pode assumir os valores 0, 1, 2, ou 3.

Se a moeda é justa, cada um dos 8 resultados do espaço amostral tem a mesma probabilidade, ou seja, $1/8$.

Assim, podemos calcular

$$p(X = 3) = p(HHH) = 1/8,$$

$$p(X = 2) = p(HHT) + p(HTH) + p(THH) = 3/8,$$

$$p(X = 1) = p(TTH) + p(THT) + p(HTT) = 3/8, \quad e$$

$$p(X = 0) = p(TTT) = 1/8,$$

e a distribuição de X é $\{(0, 1/8), (1, 3/8), (2, 3/8), (3, 1/8)\}$.

O Teorema de Bayes

O Teorema de Bayes: Introdução

- Em muitas situações temos que determinar a probabilidade de um certo evento ocorrer levando em conta evidências parciais para este evento.
- Algumas evidências contam a favor da ocorrência do evento, outras contam contra.
- À medida que novas evidências são coletadas, é possível obter uma estimativa mais precisa da probabilidade do evento de interesse ocorrer.

O Teorema de Bayes: Introdução

- Por exemplo, um júri deve decidir se um réu é culpado ou inocente.
 - Assuma que, a princípio, a probabilidade de o réu ser culpado é de 50%.
 - Ao longo do julgamento, a acusação aponta evidências da culpa do réu: a arma utilizada no crime pertence ao réu, havia sangue da vítima nas roupas do réu, etc.

Dadas estas evidências, a probabilidade do réu ser culpado aumenta.

- Já a defesa aponta evidências da inocência do réu: um álibi indica que o réu não estava na cena do crime, o réu não tinha motivo aparente para cometer o crime, etc.

Dadas estas evidências, a probabilidade do réu ser culpado diminui.

- O júri deve considerar cada evidência e atualizar apropriadamente a probabilidade de o réu ser culpado.
- Ao final do julgamento, o júri considera o réu culpado se probabilidade de culpa dadas as evidências é alta o suficiente (por exemplo, acima de 95%).

O Teorema de Bayes: Introdução

- O **Teorema de Bayes** provê um método preciso para atualizar a probabilidade de um evento levando em conta evidências conhecidas.
- O Teorema de Bayes é a base de **métodos Bayesianos** de inferência, utilizados em áreas como:
 - (a) inteligência artificial,
 - (b) aprendizado de máquina,
 - (c) engenharia,
 - (d) medicina,
 - (e) direito,
 - (f) ...

O Teorema de Bayes

- Antes de apresentar o Teorema de Bayes, vamos apresentar o seguinte lema.
- **Lema:** Sejam E e F dois eventos em um espaço amostral S . Então

$$p(E) = p(E \cap F) + p(E \cap \bar{F}).$$

Prova. Primeiro mostramos que o evento E pode ser escrito como $(E \cap F) \cup (E \cap \bar{F})$:

$$\begin{aligned} E &= E \cap S && \text{(pois } E \subseteq S) \\ &= E \cap (F \cup \bar{F}) && \text{(pois } F \cup \bar{F} = S) \\ &= (E \cap F) \cup (E \cap \bar{F}) && \text{(pela distributividade).} \end{aligned}$$

Notando que $(E \cap F)$ e $(E \cap \bar{F})$ são disjuntos (ou seja, não possuem nenhum elemento em comum), temos que

$$|E| = |(E \cap F) \cup (E \cap \bar{F})| = |(E \cap F)| + |(E \cap \bar{F})|.$$

- **Prova.** (Continuação)

Assim, podemos escrever

$$\begin{aligned} p(E) &= \frac{|E|}{|S|} \\ &= \frac{|(E \cap F) \cup (E \cap \bar{F})|}{|S|} \\ &= \frac{|(E \cap F)| + |(E \cap \bar{F})|}{|S|} \\ &= \frac{|(E \cap F)|}{|S|} + \frac{|(E \cap \bar{F})|}{|S|} \\ &= p(E \cap F) + p(E \cap \bar{F}). \end{aligned}$$



O Teorema de Bayes

- **Teorema: (Teorema de Bayes)** Sejam E e F eventos de um espaço amostral S tais que $p(E) \neq 0$ e $p(F) \neq 0$. Então

$$p(F | E) = \frac{p(F)p(E | F)}{p(E)} = \frac{p(F)p(E | F)}{p(F)p(E | F) + p(\bar{F})p(E | \bar{F})}.$$

Prova. Podemos escrever:

$$\begin{aligned} p(F | E) &= \frac{p(E \cap F)}{p(E)} && \text{(pela def. de prob. condicional)} \\ &= \frac{p(F)p(E | F)}{p(E)} && \text{(pois } p(E | F) = p(E \cap F)/p(F)\text{)} \\ &= \frac{p(F)p(E | F)}{p(E \cap F) + p(E \cap \bar{F})} && \text{(pelo lema anterior)} \\ &= \frac{p(F)p(E | F)}{p(F)p(E | F) + p(\bar{F})p(E | \bar{F})} && \text{(pela def. de prob. condicional).} \end{aligned}$$

□

- Exemplo 20: A população de uma certa cidade é composta de 52% de homens e 48% de mulheres.

Um entrevistador para uma pessoa aleatoriamente em uma rua desta cidade para fazer uma pesquisa.

Qual a probabilidade da pessoa selecionada ser homem?

Solução: A probabilidade de uma pessoa aleatoriamente selecionada ser homem é 0.52 (e a probabilidade da pessoa ser mulher é 0.48).



O Teorema de Bayes

- Exemplo 21: Considere a mesma cidade do exemplo anterior, em que a população é composta de 52% de homens e 48% de mulheres.

Um entrevistador para uma pessoa aleatoriamente em uma rua desta cidade para fazer uma pesquisa.

O entrevistador nota que a pessoa selecionada está fumando. Nesta cidade, 9% dos homens e 2% das mulheres são fumantes.

Qual a probabilidade da pessoa selecionada ser homem?

Solução: Para resolver esta questão, vamos formalizá-la com mais cuidado.

Vamos usar M para representar que a pessoa é homem (*male*), e \bar{M} para representar que a pessoa é mulher (*not male*).

Vamos usar C para representar que a pessoa fuma cigarros, e \bar{C} para representar que a pessoa não fuma.

- Exemplo 21: (Continuação)

Queremos calcular a probabilidade da pessoa selecionada ser homem, dado que ela fuma, ou seja, queremos calcular $p(M | C)$.

Para isto, podemos usar o Teorema de Bayes, que diz que

$$p(M | C) = \frac{p(M)p(C | M)}{p(C)} = \frac{p(M)p(C | M)}{p(M)p(C | M) + p(\bar{M})p(C | \bar{M})}.$$

Note que

- $p(M) = 0.52$ e $p(\bar{M}) = 0.48$, como calculamos no exemplo anterior,
- $p(C | M) = 0.09$, já que 9% dos homens fumam, e
- $p(C | \bar{M}) = 0.02$, já que 2% das mulheres fumam.

- Exemplo 21: (Continuação)

Substituindo os valores encontrados na fórmula de Bayes, obtemos

$$\begin{aligned} p(M | C) &= \frac{p(M)p(C | M)}{p(M)p(C | M) + p(\bar{M})p(C | \bar{M})} \\ &= \frac{0.52 \cdot 0.09}{0.52 \cdot 0.09 + 0.48 \cdot 0.02} \\ &= \frac{0.0468}{0.0564} \\ &\approx 0.83, \end{aligned}$$

de onde concluímos que se a pessoa selecionada fuma, com 83% de chance ela é homem.



O Teorema de Bayes: Interpretação

- O Teorema de Bayes pode ser descrito como uma maneira de atualizar a probabilidade de um evento F quando uma nova evidência E é apresentada.
- A fórmula

$$p(F | E) = \frac{p(F)p(E | F)}{p(E)}$$

indica que a probabilidade $p(F | E)$ do evento F dado o evento E :

1. aumenta proporcionalmente à probabilidade inicial $p(F)$ do evento F ;
2. aumenta proporcionalmente à probabilidade $p(E | F)$ da evidência E ocorrer dado que o evento F ocorreu;
3. diminui proporcionalmente à probabilidade $p(E)$ da evidência E ocorrer independentemente de F .

O Teorema de Bayes: Interpretação

- Podemos reescrever o Teorema de Bayes da seguinte forma.

Se a probabilidade inicial de F é $p(F)$, quando uma evidência E é apresentada calculamos a probabilidade atualizada $p(F | E)$ como

$$\underbrace{p(F | E)}_{\text{prob. atualizada}} = \underbrace{p(F)}_{\text{prob. inicial}} \cdot \underbrace{\frac{p(E | F)}{p(E)}}_{\text{fator de correção}}.$$

Note que podemos ver que a probabilidade atualizada $p(F | E)$ é proporcional à probabilidade inicial $p(F)$ e a um fator de correção $p(E | F)/p(E)$.

- Estas observações têm implicações relevantes em exemplos práticos.

É a relação entre a probabilidade inicial de F e o fator de correção que determinam o quanto a probabilidade de F deve ser atualizada dada a evidência E .

O exemplo seguinte demonstra consequências contra-intuitivas, porém importantes, destas observações.

O Teorema de Bayes: Interpretação

- Exemplo 22: Suponha que uma certa doença rara se manifeste em apenas 1 em cada 10 000 indivíduos de uma população.

Suponha ainda que exista para esta doença um exame que, apesar de bastante acurado, não é perfeito:

1. o exame resulta em positivo em 95% dos casos em que a pessoa testada tem a doença, e
2. o exame resulta em negativo em 99% dos casos em que a pessoa testada não tem a doença.

Neste caso, qual a probabilidade de uma pessoa que testa negativo para o exame não ter a doença?

E qual a probabilidade de uma pessoa que testa positivo para o exame realmente ter a doença?

O Teorema de Bayes: Interpretação

- Exemplo 22: (Continuação)

Solução: Vamos chamar de D o evento em que a pessoa tem a doença e de \bar{D} o evento em que a pessoa não tem a doença.

Vamos chamar de E o evento em que a pessoa testa positivo para o exame, e \bar{E} o evento em que a pessoa testa negativo para o exame.

Queremos calcular

- $p(\bar{D} | \bar{E})$: a probabilidade de a pessoa não ter a doença dado que o exame deu negativo, e
- $p(D | E)$: a probabilidade de a pessoa ter a doença dado que o exame deu positivo.

O Teorema de Bayes: Interpretação

- Exemplo 22: (Continuação)

Vamos começar calculando $p(\bar{D} | \bar{E})$. Pelo Teorema de Bayes,

$$p(\bar{D} | \bar{E}) = \frac{p(\bar{D})p(\bar{E} | \bar{D})}{p(\bar{E})} = \frac{p(\bar{D})p(\bar{E} | \bar{D})}{p(D)p(\bar{E} | D) + p(\bar{D})p(\bar{E} | \bar{D})}.$$

Para fazer a substituição de valores na fórmula, note que:

- a probabilidade de uma pessoa na população em geral ter a doença é $p(D) = 1/10\,000 = 0.0001$,
- a probabilidade de uma pessoa na população em geral não ter a doença é $p(\bar{D}) = 9\,999/10\,000 = 0.9999$,
- a probabilidade do exame resultar negativo para quem tem a doença é $p(\bar{E} | D) = 0.05$, e
- a probabilidade do exame resultar negativo para quem não tem a doença é $p(\bar{E} | \bar{D}) = 0.99$.

O Teorema de Bayes: Interpretação

- Exemplo 22: (Continuação)

Substituindo os valores na fórmula, obtemos

$$\begin{aligned} p(\bar{D} | \bar{E}) &= \frac{p(\bar{D})p(\bar{E} | \bar{D})}{p(\bar{E})} \\ &= \frac{p(\bar{D})p(\bar{E} | \bar{D})}{p(D)p(\bar{E} | D) + p(\bar{D})p(\bar{E} | \bar{D})} \\ &= \frac{0.9999 \cdot 0.99}{0.0001 \cdot 0.05 + 0.9999 \cdot 0.99} \\ &\approx 0.9999, \end{aligned}$$

de onde concluímos que uma pessoa que testa negativo para o exame tem 99.99% de chance de não ter a doença.

O Teorema de Bayes: Interpretação

- Exemplo 22: (Continuação)

Vamos agora calcular $p(D | E)$. Pelo Teorema de Bayes,

$$p(D | E) = \frac{p(D)p(E | D)}{p(E)} = \frac{p(D)p(E | D)}{p(D)p(E | D) + p(\bar{D})p(E | \bar{D})}.$$

Para fazer a substituição de valores na fórmula, note que:

- como já calculamos, na população em geral a probabilidade de uma pessoa ter a doença é $p(D) = 0.0001$, e a probabilidade da pessoa não ter a doença é $p(\bar{D}) = 0.9999$,
- a probabilidade do exame resultar positivo para quem tem a doença é $p(E | D) = 0.95$, e
- a probabilidade do exame resultar positivo para quem não tem a doença é $p(E | \bar{D}) = 0.01$.

O Teorema de Bayes: Interpretação

- Exemplo 22: (Continuação)

Substituindo os valores na fórmula, obtemos

$$\begin{aligned} p(D | E) &= \frac{p(D)p(E | D)}{p(E)} \\ &= \frac{p(D)p(E | D)}{p(D)p(E | D) + p(\bar{D})p(E | \bar{D})} \\ &= \frac{0.0001 \cdot 0.95}{0.0001 \cdot 0.95 + 0.9999 \cdot 0.01} \\ &\approx 0.0094, \end{aligned}$$

de onde concluímos que uma pessoa que testa positivo para o exame tem apenas 0.94% de chance de ter realmente a doença.

Isto acontece porque o fator de correção $\frac{p(E|D)}{p(E)} \approx 94$ não é suficiente para alterar drasticamente a probabilidade inicial $p(D) = 0.0001$ da pessoa estar doente, que era muito baixa.



O Teorema de Bayes: Generalização

- O Teorema de Bayes pode ser generalizado para o caso em que as evidências não são apenas do tipo presente/ausente como a seguir.
- **Teorema: (Teorema de Bayes Generalizado)** Seja E um evento de um espaço amostral S e sejam F_1, F_2, \dots, F_n eventos mutuamente exclusivos tais que $\bigcup_{i=1}^n F_i = S$.

Se $p(E) \neq 0$ e $p(F_i) \neq 0$ para todo $i = 1, 2, \dots, n$, então

$$p(F_j | E) = \frac{p(F_j)p(E | F_j)}{\sum_{i=1}^n p(F_i)p(E | F_i)}.$$

Prova. Para o aluno!

Valor esperado e Variância

Valor esperado e variância: Introdução

- O **valor esperado** de uma variável aleatória pode ser visto como uma média ponderada dos valores que esta variável assume quando o experimento é reexecutado várias vezes.

O valor esperado de uma variável aleatória representa uma espécie de ponto médio ao redor do qual os outros valores da variável estão distribuídos.

- A **variância** de uma variável aleatória é uma medida do quão esparsamente os valores da variável aleatória estão distribuídos em torno de seu valor esperado.

- O *valor esperado* (ou *esperança*) de uma variável aleatória $X(s)$ no espaço amostral S é dado por

$$E(X) = \sum_{s \in S} p(s)X(s).$$

Se o espaço amostral é infinito, o valor esperado só existe se o somatório for absolutamente convergente.

- De forma equivalente, podemos escrever

$$E(X) = \sum_{r \in X(S)} p(X = r) \cdot r,$$

pois simplesmente no somatório agrupamos todos os valores que a variável aleatória pode assumir vezes a probabilidade dela assumir tal valor.

- **Exemplo 23:** Seja X o número que obtemos ao rolar um dado não-viciado de 6 faces.

Qual o valor esperado de X ?

Solução: A variável aleatória X assume os valores $\{1, 2, 3, 4, 5, 6\}$ com probabilidade uniforme $1/6$.

Logo

$$E(X) = \frac{1}{6} \cdot 1 + \frac{1}{6} \cdot 2 + \frac{1}{6} \cdot 3 + \frac{1}{6} \cdot 4 + \frac{1}{6} \cdot 5 + \frac{1}{6} \cdot 6 = 3.5$$



- Exemplo 24: Suponha que uma moeda seja lançada três vezes.

Seja $X(s)$ a variável aleatória que mapeia o resultado s do experimento para o número de caras em s .

Qual o valor esperado de X ?

Solução: Chamando H de cara (*heads*) e T de coroa (*tails*), o espaço amostral do experimento é $S = \{HHH, HHT, HTH, HTT, THH, THT, TTH, TTT\}$.

Como a moeda é não-viciada, qualquer um dos 8 resultados possui probabilidade $1/8$.

- Exemplo 24: (Continuação)

Assim, podemos calcular:

$$\begin{aligned} E(X) &= \sum_{s \in \mathcal{S}} p(s)X(s) \\ &= \frac{1}{8} \cdot X(HHH) + \frac{1}{8} \cdot X(HHT) + \frac{1}{8} \cdot X(HTH) + \frac{1}{8} \cdot X(HTT) + \\ &\quad \frac{1}{8} \cdot X(THH) + \frac{1}{8} \cdot X(THT) + \frac{1}{8} \cdot X(TTH) + \frac{1}{8} \cdot X(TTT) \\ &= \frac{1}{8} \cdot 3 + \frac{1}{8} \cdot 2 + \frac{1}{8} \cdot 2 + \frac{1}{8} \cdot 1 + \frac{1}{8} \cdot 2 + \frac{1}{8} \cdot 1 + \frac{1}{8} \cdot 1 + \frac{1}{8} \cdot 0 \\ &= \frac{3}{2}. \end{aligned}$$



Valor esperado da distribuição binomial

- Como vimos, a distribuição binomial é a distribuição que surge da execução de n ensaios de Bernoulli independentes.

Recorde que na distribuição binomial, a probabilidade de k sucessos durante a execução de n ensaios de Bernoulli independentes (onde cada ensaio tem probabilidade de sucesso p) é dada por $C(n, k)p^k(1 - p)^{n-k}$.

- **Teorema: (Valor esperado da distribuição binomial)** O número esperado de sucessos quando n ensaios de Bernoulli independentes são executados, onde p é a probabilidade de sucesso em cada ensaio, é

$$np.$$

Prova. Para o aluno!

Valor esperado da distribuição binomial

- **Exemplo 25:** Uma moeda viciada ao ser lançada resulta em cara $3/4$ das vezes, e em coroa $1/4$ das vezes.

Qual o número esperado de caras se a moeda for lançada 100 vezes?

Solução: O experimento é um processo de Bernoulli com $n = 100$ ensaios, em que a probabilidade de sucesso (cara) é $p = 3/4$.

Portanto, o número esperado de caras no experimento é

$$np = 100 \cdot \frac{3}{4} = 75.$$



- O seguinte teorema mostra que o valor esperado é uma função linear.

Em particular, o valor esperado da soma de variáveis aleatórias é a soma dos valores esperados das variáveis aleatórias.

- **Teorema: (Linearidade do valor esperado)** Se X_i , onde $i = 1, 2, \dots, n$ é um inteiro positivo, são variáveis aleatórias em um espaço amostral S , e a e b são números reais, então

1. $E(X_1 + X_2 + \dots + X_n) = E(X_1) + E(X_2) + \dots + E(X_n)$, e
2. $E(aX + b) = aE(X) + b$.

Prova. Vamos provar cada item separadamente.

- **Prova.** (Continuação)

Para o primeiro item:

$$\begin{aligned} E(X_1 + X_2 + \dots + X_n) &= \sum_{s \in S} p(s)(X_1(s) + X_2(s) + \dots + X_n) \\ &= \sum_{s \in S} [p(s)X_1(s) + p(s)X_2(s) + \dots + p(s)X_n] \\ &= \sum_{s \in S} p(s)X_1(s) + \sum_{s \in S} p(s)X_2(s) + \dots + \sum_{s \in S} p(s)X_n \\ &= E(X_1) + E(X_2) + \dots + E(X_n). \end{aligned}$$

- **Prova.** (Continuação)

Para o segundo item:

$$\begin{aligned} E(aX + b) &= \sum_{s \in S} p(s)(aX(s) + b) && \text{(pela def.)} \\ &= \sum_{s \in S} [p(s)aX(s) + p(s)b] && \text{(distribuindo a multiplicação)} \\ &= \sum_{s \in S} p(s)aX(s) + \sum_{s \in S} p(s)b && \text{(separando o somatório)} \\ &= a \sum_{s \in S} p(s)X(s) + b \sum_{s \in S} p(s) && \text{(constantes em evidência)} \\ &= aE(X) + b \cdot 1 && \text{(pois } \sum_{s \in S} p(s) = 1) \\ &= aE(X) + b \end{aligned}$$



- **Exemplo 26:** Cinquenta clientes passam por um restaurante durante um dia. Cada um dos clientes tem uma probabilidade uniforme de deixar uma gorjeta entre 0 e 10 reais, em valores inteiros apenas.

Qual o valor esperado do total de gorjetas deixadas pelos clientes ao final de um dia?

Solução: O espaço amostral do experimento são todas as 50-tuplas em que cada elemento na tupla representa a gorjeta deixada por um cliente específico.

Se formos calcular o valor esperado diretamente neste espaço amostral, teremos um trabalho muito grande: há 11^{50} resultados possíveis no espaço amostral!

O problema pode ser simplificado usando a linearidade do valor esperado.

- Exemplo 26: (Continuação)

Seja X_i o valor de gorjeta deixado pelo cliente i , sendo $1 \leq i \leq 50$.

Sabemos que o cliente deixa uma gorjeta entre 0 e 10 reais uniformemente, ou seja, cada valor inteiro entre 0 e 10 é deixado como gorjeta com probabilidade $1/11$, logo

$$E(X_i) = \frac{1}{11} (0 + 1 + 2 + 3 + 4 + 5 + 6 + 7 + 8 + 9 + 10) = 5.$$

Estamos interessados em calcular $E\left(\sum_{i=1}^{50} X_i\right)$, e pela linearidade do valor esperado podemos fazer

$$E\left(\sum_{i=1}^{50} X_i\right) = \sum_{i=1}^{50} E(X_i) = \sum_{i=1}^{50} 5 = 50 \cdot 5 = 250,$$

e concluir que a gorjeta esperada ao final do dia é de 250 reais.



Linearidade do valor esperado

- Exemplo 27: Um par de dados de 6 faces, ambos não-viciados, é lançado. Qual o valor esperado da soma dos números obtidos?

Solução: O espaço amostral do experimento são pares (i, j) , com $1 \leq i \leq 6$ representando o resultado do lançamento do primeiro dado, e $1 \leq j \leq 6$ representando o resultado do lançamento do segundo dado.

Seja X_1 a variável aleatória que mapeia cada resultado para o número do primeiro dado, ou seja, $X_1(i, j) = i$.

Seja X_2 a variável aleatória que mapeia cada resultado para o número do segundo dado, ou seja, $X_2(i, j) = j$.

Queremos calcular $E(X_1 + X_2)$, e pela linearidade do valor esperado sabemos que $E(X_1 + X_2) = E(X_1) + E(X_2)$.

Já vimos em um exemplo anterior que o valor esperado do lançamento de um dado de 6 faces não-viciado é 3.5, concluímos:

$$E(X_1 + X_2) = E(X_1) + E(X_2) = 3.5 + 3.5 = 7.$$



Variáveis aleatórias independentes

- Já vimos que dois eventos E_1 e E_2 são independentes se, e somente se,

$$p(E_1 \cap E_2) = p(E_1)p(E_2).$$

Vamos agora estender o conceito de independência para variáveis aleatórias.

- Duas **variáveis aleatórias** X e Y num espaço amostral S são **independentes** se para todo valor de r_1 e r_2 :

$$p(X(s) = r_1 \wedge Y(s) = r_2) = p(X(s) = r_1) \cdot p(Y(s) = r_2).$$

Ou seja, X e Y são independentes se a probabilidade de X assumir o valor r_1 e Y assumir o valor r_2 simultaneamente for igual ao produto da probabilidade de X assumir o valor r_1 pela probabilidade de Y assumir o valor r_2 .

- Exemplo 28: Dois dados não-viciados de 6 faces são lançados.

Seja X_1 a variável aleatória correspondendo ao resultado obtido no primeiro dado, e X_2 , a variável aleatória correspondendo ao resultado obtido no segundo dado.

X_1 e X_2 são independentes?

Solução: As variáveis são independentes se
 $p(X_1 = r_1 \wedge X_2 = r_2) = p(X_1 = r_1)p(X_2 = r_2)$.

O espaço amostral de X_1 e X_2 é o mesmo: $S = \{1, 2, 3, 4, 5, 6\}$. Além disso, a distribuição de X_1 e X_2 é uniforme, ou seja, $1/6$ para qualquer resultado.

Logo, deduzimos que para quaisquer valores de r_1 e r_2

$$p(X_1 = r_1)p(X_2 = r_2) = \frac{1}{6} \cdot \frac{1}{6} = \frac{1}{36}.$$

- Exemplo 28: (Continuação)

Agora vamos considerar a probabilidade $p(X_1 = r_1 \wedge X_2 = r_2)$ de os dois dados lançados assumirem valores ao mesmo tempo.

Nesse caso o espaço amostral tem 36 resultados possíveis (um para cada combinação dos dois dados). Como todos os resultados são igualmente prováveis, a probabilidade de cada um é $1/36$.

Assim, verificamos que para quaisquer $r_1, r_2 \in S$

$$p(X_1 = r_1 \wedge X_2 = r_2) = p(X_1 = r_1)p(X_2 = r_2) = \frac{1}{36},$$

e as variáveis X_1 e X_2 são independentes.



Variáveis aleatórias independentes

- Exemplo 29: Dois dados não-viciados de 6 faces são lançados.

Seja X_1 a variável aleatória correspondendo ao resultado obtido no primeiro dado, e X_2 , a variável aleatória correspondendo à soma dos resultados de cada dado.

X_1 e X_2 são independentes?

Solução: As variáveis são independentes se para todo r_1, r_2
 $p(X_1 = r_1 \wedge X_2 = r_2) = p(X_1 = r_1)p(X_2 = r_2)$.

Vamos mostrar um contra-exemplo que prova que as variáveis não são independentes.

Tomando $r_1 = 1$ e $r_2 = 12$, temos que

$$p(X_1 = 1 \wedge X_2 = 12) = 0,$$

pois não há como o primeiro dado resultar no valor 1 e a soma dos dados resultar no valor 12 ao mesmo tempo.

- Exemplo 29: (Continuação)

Por outro lado:

- $p(X_1 = 1) = 1/6$, pois o dado é não-viciado, e
- $p(X_2 = 12) = 1/36$, pois apenas em 1 dos 36 resultados possíveis para o lançamento de dois dados a soma dos resultados dá 12 (quando ambos os dados resultam em 6).

Logo,

$$p(X_1 = 1)p(X_2 = 12) = \frac{1}{6} \cdot \frac{1}{36} = \frac{1}{216},$$

o que difere de $p(X_1 = 1 \wedge X_2 = 12) = 0$ e, portanto, X_1 e X_2 não são independentes.



Variáveis aleatórias independentes

- Se duas variáveis aleatórias são independentes, o valor esperado de seu produto pode ser calculado como o produto de seus valores esperados.
- **Teorema:** Se X e Y são variáveis independentes em um espaço amostral S , então

$$E(XY) = E(X)E(Y).$$

Prova. Para o aluno!

- O valor esperado de uma distribuição sozinho pode levar a comparações enganosas entre distribuições de probabilidade.

Distribuições de probabilidade muito distintas podem ter valores esperados parecidos.

- A variância de uma variável aleatória é uma medida do quão dispersos são os valores desta variável em torno de seu valor esperado.
- Seja X uma variável aleatória num espaço amostral S . A **variância** de X , denotada por $V(X)$, é dada por

$$V(X) = \sum_{s \in S} p(s)[X(s) - E(X)]^2.$$

O desvio-padrão de X , denotado por $\sigma(X)$, é definido como $\sigma(X) = \sqrt{V(X)}$.

- **Teorema:** Se X é uma variável aleatória num espaço amostral S , então

$$V(X) = E(X^2) - [E(X)]^2.$$

Prova.

$$\begin{aligned} V(X) &= \sum_{s \in S} p(s)[X(s) - E(X)]^2 \\ &= \sum_{s \in S} p(s)[(X(s))^2 - 2X(s)E(X) + (E(X))^2] \\ &= \sum_{s \in S} [p(s)(X(s))^2 - p(s)2X(s)E(X) + p(s)(E(X))^2] \\ &= \sum_{s \in S} p(s)(X(s))^2 - \sum_{s \in S} p(s)2X(s)E(X) + \sum_{s \in S} p(s)(E(X))^2 \\ &= E(X^2) - 2E(X) \sum_{s \in S} p(s)X(s) + (E(X))^2 \sum_{s \in S} p(s) \\ &= E(X^2) - 2E(X)E(X) + (E(X))^2 \cdot 1 \\ &= E(X^2) - [E(X)]^2 \end{aligned}$$



- **Teorema:** Se X_1, X_2, \dots, X_n são variáveis aleatórias independentes dois-a-dois num espaço amostral S , então

$$V(X_1 + X_2 + \dots + X_n) = V(X_1) + V(X_2) + \dots + V(X_n).$$

Prova.

Exercício para o aluno!

Apêndice

Falácias probabilísticas

- Uma **falácia** é um raciocínio errado com aparência de verdadeiro.

Uma falácia é um argumento logicamente inconsistente, sem fundamento, inválido, ou falho na tentativa de provar o que alega.

- O termo “falácia” deriva do verbo latino “fallere”, que significa “enganar”.

Argumentos que se destinam à persuasão podem parecer convincentes para grande parte do público apesar de conterem falácias, mas não deixam de ser falsos por causa disso.

- Reconhecer as falácias é por vezes difícil.

Os argumentos falaciosos podem ter validade emocional, íntima, psicológica, mas não validade lógica.

- Exemplos de **falácias lógicas** são:

(a) *ad hominem*, (b) *ad populum*, (c) espantalho, (d) etc.

- **Falácias probabilísticas** são por vezes ainda mais difíceis de se identificar, porque vão contra nossa intuição.

- Falácia de **ignorar a frequência de base**:

considerar apenas a probabilidade condicional de um evento dadas informações específicas, ignorando a frequência de base do evento.

- Exemplo 30: Pedro é introvertido, inteligente e gosta de biologia.

Qual a profissão mais provável de Pedro: vendedor de uma loja ou neurocirurgião?

A resposta é vendedor de uma loja.

Muitas pessoas ficam tentadas a responder neurocirurgião, porque a descrição de Pedro se assemelha ao estereótipo de um neurocirurgião.

Entretanto, a proporção-base na população é de milhares (ou milhões) de vendedores para cada neurocirurgião, logo é mais provável que ele seja apenas um vendedor atípico do que um cirurgião típico.



- **Exemplo 31:** Relembre o exemplo que vimos sobre um exame quem tem 95% de probabilidade de resultar positivo se o indivíduo testado possui uma dada doença.

Se um indivíduo testa positivo para a doença neste exame, a princípio não se pode determinar qual a probabilidade deste indivíduo realmente ter a doença.

A frequência de base da ocorrência da doença na população, assim como a probabilidade o teste resultar positivo para alguém que não tem a doença, tem que ser levada em consideração.

Como vimos no exemplo citado, se a frequência de base na população é de 1 indivíduo contaminado para cada 10 000 indivíduos, e a probabilidade do exame resultar em um falso positivo é de 1%, a probabilidade de um indivíduo que testa positivo realmente ter a doença é de apenas 0.94%.



Falácias probabilísticas: Falácia do apostador

- Falácia do **apostador**:

assumir que a distribuição de probabilidade em um conjunto pequeno de experimentos deve necessariamente refletir a distribuição de um conjunto grande de experimentos.

- Exemplo 32: *“As últimas 5 rodadas da roleta deram um número vermelho: isto é sinal de que muito provavelmente o próximo número será preto. Vou apostar todas as minhas fichas no preto!”* ◀

- Outra versão da falácia do apostador, oposta à primeira, é assumir que a probabilidade de um evento necessariamente segue a distribuição dos experimentos mais recentes.

- Exemplo 33: *“As últimas 5 rodadas da roleta deram um número vermelho: isto é sinal de que estamos em uma “onda vermelha”, e muito provavelmente o próximo número será também vermelho. Vou apostar todas as minhas fichas no vermelho!”* ◀

- **Paradoxo de Simpson:**

dados agregados podem sugerir uma correlação que pode ser completamente revertida quando os dados são analisados de forma segmentada.

- Exemplo 34: Uma pesquisa nos EUA descobriu que:

1. o salário médio dos membros do grupo A é de 1 590 US\$ por mês, e
2. o salário médio dos membros do grupo B é de 2 500 US\$ por mês.

- Um jornal computa a razão $1590/2500 = 0.64$ e divulga:

“Desigualdade salarial nos EUA: pessoas do grupo A recebem, em média, 64 centavos para cada dólar recebido por pessoas do grupo B !”

- Outro jornal separa as pessoas em profissões e divulga:

“Desigualdade salarial nos EUA: em todas as profissões, pessoas do grupo A sempre recebem 10% a mais que pessoas do grupo B !”

As duas manchetes estão corretas. Como isso é possível?

Falácias probabilísticas: Paradoxo de Simpson

- Exemplo 34: (Continuação)

Quando consultamos os dados da pesquisa, observamos o seguinte:

Grupo	Profissão 1	Profissão 2	Profissão 3
Salário do grupo A	1 100 USD	2 200 USD	3 300 USD
Salário do grupo B	1 000 USD	2 000 USD	3 000 USD
Pessoas do grupo A	600	300	100
Pessoas do grupo B	100	300	600


- Média salarial A: $600 \cdot 1100 \text{ USD} + 300 \cdot 2200 \text{ USD} + 100 \cdot 3300 \text{ USD} / 1000 = 1590 \text{ USD}$
- Média salarial B: $100 \cdot 1000 \text{ USD} + 300 \cdot 2000 \text{ USD} + 600 \cdot 3000 \text{ USD} / 1000 = 2500 \text{ USD}$
- Mas, controlando por profissão, cada membro A sempre ganha 10% a mais que cada membro do grupo B na mesma profissão!

Ou seja, há desigualdade, mas quem seria o grupo “beneficiado”?

Falácias probabilísticas: Paradoxo de Simpson

- Exemplo 34: (Continuação)

Isto ocorre porque, apesar de em cada profissão cada membro do grupo A sempre ganhar 10% a mais que membros do grupo B , existem mais membros do grupo B nas faixas salariais bem pagas, o que puxa a média para cima!



Se há desigualdade, não é a de que membros do grupo A são mais bem pagos que membros do grupo B na mesma profissão.

A desigualdade está na escolha das profissões!



Fórmulas para permutações e combinações

Nº arranjos de r elementos; conjunto de n	Ordem dos elementos não importa	Ordem dos elementos importa
Elementos não podem se repetir	r -combinação: $C(n, r) = \frac{n!}{r!(n-r)!}$	r -permutação: $P(n, r) = \frac{n!}{(n-r)!}$
Elementos podem se repetir	r -combinação com repetição: $C(n + r - 1, r)$	r -permutação com repetição: n^r