

# **Conceitos da Teoria de Probabilidade**

*Física Estatística - F 604*

Silvio A. Vitiello

Prosper - Latex

# Conjunto

---

- Se  $S = \{A_1, A_2, \dots, A_n\}$  é o conjunto de *todas* possibilidades que um experimento pode dar,  $S$  é chamado de *espaço amostral* deste experimento e cada um de seus elementos de ponto amostral ou evento elementar.
- Empregamos a palavra *amostral* para aludir a origem estatística dos termos.
- Uma coleção parcial de elementos de  $S$  é chamada de *subconjunto*. Casos extremos destes *conjuntos*:
  - O conjunto é o próprio  $S$
  - O conjunto não possui nenhum ponto — *conjunto vazio* —  $\emptyset$
- Um *evento* é um subconjunto do espaço amostral de um experimento.
- Um evento não é elementar se a ele estiver associado mais do que um elemento ou evento de  $S$ .

## Operações

- $A \cup B$  denota a união de dois conjuntos.  
É o conjunto de todos os pontos pertencentes a  $A$  ou  $B$  ou a ambos.
- $A \cap B$  denota a intersecção de dois conjuntos.  
É o conjunto de todos os pontos pertencentes a ambos os conjuntos.

# Probabilidade

---

- Probabilidade é um número que resume a possibilidade de obtermos um certo evento em um experimento.
- Alternativamente: A probabilidade  $P(A)$  de um evento  $A$  é a razão do número de casos favoráveis ao evento  $m$  pelo número total  $n$  de casos, com tanto que todos eles sejam equiprováveis:  $P(A) = \frac{m}{n}$ .
- Uma medida de probabilidade é uma função  $P$  que satisfaz:
  1. Se  $A$  é um possível evento de um experimento então o valor da função, sua probabilidade, é  $P(A) \geq 0$
  2. Se dois eventos são mutuamente exclusivos  $A \cap B = \emptyset$  o valor de  $P$  é  $P(A \cup B) = P(A) + P(B)$
  3.  $P(S) = 1$
- A *probabilidade* de um evento  $A \subset S$  é obtida adicionando as probabilidades atribuídas aos elementos do subconjunto de  $S$  que correspondem a  $A$ .

# Propriedades

---

- Se os eventos  $A_1, A_2, \dots, A_m$  são mutuamente exclusivos e exaustivos, então

$$A_1 \cup A_2 \cup \dots \cup A_m = S$$

Os  $m$  eventos formam uma *partição* do espaço amostral  $S$  em  $m$  subconjuntos.

Se  $A_1, A_2, \dots, A_m$  formam uma partição, então

$$P(A_1) + P(A_2) + \dots + P(A_m) = 1$$

- $P(A \cup B)$  é a probabilidade do evento  $A$  ou do evento  $B$  ou ambos ocorrerem.

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

$P(A \cap B)$  \_\_ a probabilidade de ambos eventos ocorrerem \_\_ deve ser subtraída, já que  $P(A) + P(B)$  leva em conta a região  $A \cap B$  duas vezes.

# *Eventos independentes*

---

- Experimentos *independentes* correspondem a noção intuitiva de experimentos repetidos sob condições identicas
  - um sistema utilizado ao longo do tempo
  - diversos sistemas idênticos empregados em um mesmo instante → *ensemble*
- Se  $N$  experimentos idênticos e independentes (sem memória do aconteceu anteriormente) forem repetidos e  $N \rightarrow \infty$ , esperamos que a fração dos eventos  $A$  ( $N_A/N$ ) aproxime-se de  $P(A)$ .
- Os eventos  $A$  e  $B$  são independentes se e somente se  $P(A \cap B) = P(A)P(B)$ .  
Eventos independentes não são mutuamente exclusivos onde temos  $P(A \cap B = \emptyset) = 0$

# *Ensemble*

---

- Na discussão da entropia, postulamos que são iguais as probabilidades de encontrar um sistema fechado em qualquer estado microscópico consistente com seus vínculos. Esta hipótese atribui estas probabilidades apelando a simetria do sistema.
- Um ensemble de sistemas é uma coleção de sistemas idênticos.  
Cada réplica do sistema no ensemble está em um dos estados acessíveis ao sistema.
- Numa visão originalmente proposta por Gibbs, podemos substituir médias temporais por médias em um ensemble.

# Probabilidade condicional

---

- A *probabilidade condicional* do evento  $A$  ocorrer assumindo que  $B$  tenha ocorrido é denotada por  $P(A|B)$  e dada por

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

- Uma vez que  $P(A \cap B) = P(B \cap A)$ :

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

- Se  $A$  e  $B$  são independentes:  $P(A|B) = P(A)$
- A probabilidade condicional  $P(A|B)$  é essencialmente a probabilidade do evento  $A$  se usamos o conjunto  $B$  como espaço amostral ao invés de  $S$ .

# *Contagem*

---

- Sejam duas operações tais que uma pode ser feita de  $m$  maneiras e a outra em  $n$ .
  - Princípio de Adição: Se as operações são mutuamente exclusivas então uma operação qualquer pode ser feita de  $m + n$  modos.
  - Princípio da Multiplicação: Se uma das operações é executada em uma de suas possíveis maneiras e a seguir a outra é executada em uma das suas próprias maneiras então as duas operações podem ser executadas de  $m \times n$  maneiras.

## *Permutações e Combinações*

- Uma *permutação* é um dos arranjos de um conjunto de objetos distintos em uma dada ordem. O número de diferentes permutações de um conjunto de  $N$  objetos é  $N!$
- O número de permutações  $P_R^N$  de  $R$  objetos tomados de um conjunto de  $N$  elementos distintos é  $P_R^N = \frac{N!}{(N-R)!}$
- Uma *combinação* é a seleção de alguns dos objetos de um conjunto formado de elementos distintos sem preocupação com a ordem da escolha. O número de combinações de  $R$  objetos tomados de um conjunto de  $N$  elementos é

$$C_R^N = \frac{N!}{R!(N-R)!}$$

# *Cultura Geral*

---

O *Santo Império Romano* era um complexo de terras na Europa central e ocidental inicialmente regido pelos francos e depois por reis alemães. Da coroação de Carlos Magno em 800, perdurou por dez séculos.

*Voltaire* foi uma das mais influentes figuras do iluminismo francês e da Europa no Sec. XVIII, filósofo, poeta, dramaturgo, ensaísta, historiador e escritor.

# Variáveis aleatórias

---

Segundo Voltaire: O Santo Império Romano não era santo, nem império e nem romano.  
Similarmente uma variável aleatória não é aleatória nem uma variável:

Uma variável aleatória é uma função definida em um espaço amostral.

- Alternativamente: Uma quantidade cujo valor é um número determinada por um evento de um experimento é chamada *variável aleatória*.
- Uma variável aleatória  $X$  em um espaço amostral  $S$  (contável) é uma função numérica que mapeia os elementos de  $S$ .
- As possíveis realizações da v.a.  $X$  são denotadas por  $\{x_i\}$ .

# *Distribuição e valor esperado*

---

- A probabilidade de conjunto de pontos amostrais pode ser determinada pelos valores de variáveis aleatórias

$$\{a \leq X \leq b\} = \{A | a \leq X(A) \leq b\}$$

- Notação  $p_n = P(X = x_n)$
- $P(a \leq X \leq b) = \sum_{a \leq x_n \leq b} p_n$
- Função de distribuição de  $X$ :  $F_X(x) = P(X \leq x) = \sum_{x_n \leq x} p_n$
- $P(a \leq X \leq b) = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a)$
- Valor médio ou esperado:  $\langle X \rangle = E(X) = \sum_n X(A_n)P(A_n) = \sum_n x_n P(A_n) = \mu$
- Segundo momento:  $E(X^2) = \sum_n X^2(A_n)P(A_n)$

# Variáveis aleatórias com densidades

---

- Função densidade
  1.  $\forall x : f(x) \geq 0$
  2.  $\int_{-\infty}^{\infty} f(x)dx = 1$
- $P(a \leq X \leq b) = \int_a^b f(x)dx$
- Função de distribuição de  $X$ :  $F_X(x) = P(X \leq x) = \int_{-\infty}^x f(u)du$
- $F'_X(x) = f(x)$
- Valor médio ou esperado:  $\langle X \rangle = E(X) = \int_{-\infty}^{\infty} xf(x)dx = \mu$
- Segundo momento:  $E(X^2) = \int_{-\infty}^{\infty} x^2 f(x)dx$

# Variância

---

$$\text{Var } (X) = E(X^2) - E(X)^2 = E((X - \mu)^2)$$

Medida de quanto os valores estão espalhados em torno da média

# Distribuição Binomial

---

- Aplicação: Um número  $N$  de experimentos ou de sistemas e dois eventos possíveis
- Experimentos/sistemas independentes
- $p$  é a probabilidade de um dos eventos ocorrer (coroas, spin para cima, etc)
- $q = 1 - p$  é probabilidade do outro evento
- Dois estados para cada sistema  $\Rightarrow 2^N$  é o número total de estados possíveis
- $P(\text{um particular estado com } n \text{ spins para cima}) = p^n q^{N-n}$
- $P(\text{de qualquer estado com } n \text{ spins para cima}) = \binom{N}{N-n} p^n q^{N-n}$
- Normalização:  $1 = (p + q)^N = \sum_{n=0}^N \binom{N}{n} p^n q^{N-n}$

# Valor médio da distribuição binomial

---

Se uma medida de  $y$  produz  $n$

- $\langle y \rangle = \sum_{n=0}^N n \binom{N}{n} p^n q^{N-n}$ 
  - $\frac{\partial(p+q)^N}{\partial p} = \frac{\partial \sum_{n=0}^N \binom{N}{n} p^n q^{N-n}}{\partial p} \Rightarrow N(p+q)^{N-1} = \sum_{n=0}^N n \binom{N}{n} p^{n-1} q^{N-n}$
  - $Np(p+q)^{N-1} = \sum_{n=0}^N n \binom{N}{n} p^n q^{N-n}$
- $p+q=1 \Rightarrow Np = \sum_{n=0}^N n \binom{N}{n} p^n q^{N-n} = \langle y \rangle$
- $\text{Var } (y) = Npq \Rightarrow \sigma_N = \sqrt{Npq}$  e portanto  $\frac{\sigma_N}{\langle y \rangle} = \sqrt{\frac{q}{p}} \frac{1}{\sqrt{N}}$
- Se  $N \approx N_0$  então  $\sigma_N/\langle y \rangle \approx 10^{-12}$  (desvio relativo da média)
  - Portanto apesar dos parâmetros macroscópicos serem variáveis aleatórias, suas flutuações são tão pequenas que podem ser ignoradas.
  - Exemplo: falamos da energia de um sistema em contato com um reservatório térmico, apesar desta grandeza ser uma variável aleatória que flutua constantemente.

# Distribuição Gaussiana (Normal)

---

A distribuição Gaussiana é a mais comum e importante nas aplicações.

O teorema do limite central garante que a soma (ou a média) de um grande número de v.a. distribuídas de forma idêntica e independente aproxima-se da distribuição Gaussiana.

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$\text{onde } \langle x \rangle = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} x e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx = \mu, \quad \text{Var } (x) = \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} (x - \mu)^2 e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx = \sigma^2$$

Distribuição normal padrão:  $\mu = 0$  e  $\sigma = 1$

$$p(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

Equivalentemente  $x \rightarrow x - \mu$  e a seguir  $x \rightarrow x/\sigma$ .

# Função de Distribuição

---

$$\begin{aligned}F_X(x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^x e^{-\frac{(u-\mu)^2}{2\sigma^2}} du \\&= \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left(\frac{x-\mu}{\sigma\sqrt{2}}\right)\end{aligned}$$

Função erro

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-u^2} du$$

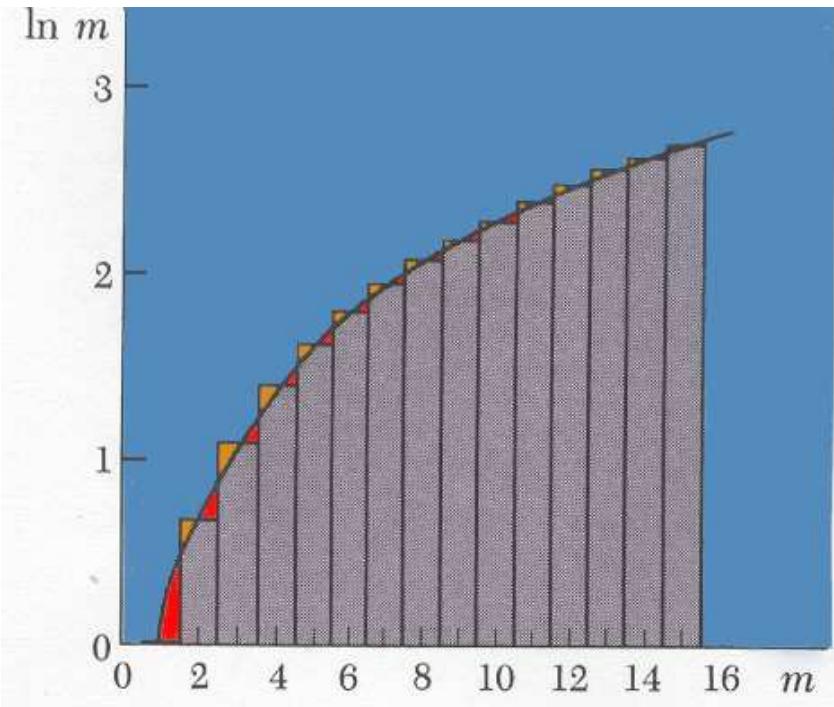
Função erro complementar

$$\operatorname{erfc}(x) = \frac{2}{\sqrt{\pi}} \int_x^\infty e^{-u^2} du$$

$$\operatorname{erf}(x) + \operatorname{erfc}(x) = 1$$

# Valor de $\ln n!$ para $n$ grande

---



$$n! = 1 \cdot 2 \cdots n$$

$$\ln n! = \sum_{m=1}^n \ln m$$

$$\ln n! \approx \int_1^n \ln x dx = x \ln x - x \Big|_1^n$$

Se  $n \gg 1$  então:

$$\boxed{\ln n! \approx n \ln n - n}$$

Aproximação de Stirling:  $\ln n! \approx \frac{1}{2} \ln(2\pi n) + n \ln n - n$

# Função gama

---

$$\Gamma(z) = \int_0^\infty t^{z-1} e^{-t} dt$$

Integrando por partes:

$$\begin{aligned}\Gamma(z) &= -t^{z-1} e^{-t} \Big|_0^\infty + (z-1) \int_0^\infty t^{z-2} e^{-t} dt \\ &= (z-1) \int_0^\infty t^{z-2} e^{-t} dt \\ &= (z-1)\Gamma(z-1) \Rightarrow \boxed{n! = \Gamma(z+1)}\end{aligned}$$

$$I_m = 2 \int_0^\infty x^m e^{-x^2} dx ; \quad (m > -1) \xrightarrow[2dx=dy/\sqrt{y}]{x^2=y} I_m = \int_0^\infty y^n e^{-y} dy = \Gamma(n+1) ; \quad \left( n = \frac{m-1}{2} \right)$$

$$I_{2\ell} = \Gamma(\ell + 1/2) = (\ell - \frac{1}{2})(\ell - \frac{3}{2}) \cdots \frac{1}{2} \sqrt{\pi}; \quad (\Gamma(1/2) = \sqrt{\pi})$$

$$I_{2\ell+1} = \Gamma(\ell + 1) = \ell!$$

# Distribuição Gaussiana como limite da Binomial

---

Sistemas com  $N \gg 1$  spins,  $N_{\parallel}, N_{\neq} \gg 1 \Rightarrow 2s \approx \pm N$ . Portanto,  $s$  não precisa ser grande

$$\left. \begin{array}{lcl} N_{\parallel} - N_{\neq} & = & 2s \\ N_{\parallel} + N_{\neq} & = & N \end{array} \right\} \quad \left. \begin{array}{lcl} N_{\parallel} & = & N/2 + s \\ N_{\neq} & = & N/2 - s \end{array} \right.$$

$$p_s = \frac{N!}{(N/2+s)!(N/2-s)!} p^{\frac{N}{2}+s} q^{\frac{N}{2}-s}$$

Aproximação de Stirling:  $n! \approx \sqrt{2\pi n} n^N e^{-N}$

$$\begin{aligned} p_s &\approx \sqrt{\frac{2\pi N}{2\pi(N/2+s)2\pi(N/2-s)}} \frac{N^N}{(N/2+s)^{(N/2+s)}(N/2-s)^{(N/2-s)}} e^0 p^{\frac{N}{2}+s} q^{\frac{N}{2}-s} \\ &= \sqrt{\frac{1}{2\pi N(1/2+s/N)(1/2-s/N)}} \frac{1}{(1/2+s/N)^{(N/2+s)}(1/2-s/N)^{(N/2-s)}} p^{\frac{N}{2}+s} q^{\frac{N}{2}-s} \\ &= \sqrt{\frac{1}{2\pi N}} \left( \frac{p^{\frac{N}{2}+s}}{(1/2+s/N)^{(N/2+s+1/2)}} \right) \left( \frac{q^{\frac{N}{2}-s}}{(1/2-s/N)^{(N/2-s+1/2)}} \right) \\ &= \sqrt{\frac{1}{2\pi Npq}} \left( \frac{p}{1/2+s/N} \right)^{(N/2+s+1/2)} \left( \frac{q}{1/2-s/N} \right)^{(N/2-s+1/2)} \\ &\approx \sqrt{\frac{1}{2\pi Npq}} \left( \frac{p}{1/2+s/N} \right)^{(N/2+s)} \left( \frac{q}{1/2-s/N} \right)^{(N/2-s)} \text{ pois } \frac{N}{2} \pm s + \frac{1}{2} \approx \frac{N}{2} \pm s \end{aligned}$$

# Distribuição Gaussiana como limite da Binomial

---

Esta função possui um pico pronunciado em torno do valor médio de  $s$

$$\langle s \rangle = \mu = \langle N_{\parallel} \rangle - N/2 = N(p - 1/2), \text{ já que } \frac{\sigma_N}{\langle y \rangle} \propto N^{-1/2}$$

Podemos ver isto explicitamente. É conveniente tomar o  $\ln$  de

$$p_s = \sqrt{\frac{1}{2\pi Npq}} \left( \frac{p}{1/2 + s/N} \right)^{(N/2+s)} \left( \frac{q}{1/2 - s/N} \right)^{(N/2-s)}$$

$$\ln p_s = -\frac{1}{2} \ln(2\pi Npq) + \left(\frac{N}{2} + s\right) (\ln p - \ln(1/2 + s/N)) + \left(\frac{N}{2} - s\right) (\ln q - \ln(1/2 - s/N))$$

$$\frac{\partial \ln p_s}{\partial s} = \ln p - \ln(1/2 + s/N) - 1 - \ln q + \ln(1/2 - s/N) + 1$$

Conforme afirmamos:  $\left. \frac{\partial \ln p_s}{\partial s} \right|_{s=\mu} = 0$       Vamos expandir  $\ln p_s$  em torno de  $s = \mu$

$$\frac{\partial^2 \ln p_s}{\partial s^2} = -\frac{1}{N/2 + s} - \frac{1}{N/2 - s}$$

$$\left. \frac{\partial^2 \ln p_s}{\partial s^2} \right|_{s=\mu} = -\frac{1}{Np} - \frac{1}{N(1-p)} = -\frac{p+q}{Npq} = -\frac{1}{Npq}$$

# Distribuição Gaussiana como limite da Binomial

---

Se  $\sigma^2 = Npq$

$$\ln p_s|_{s=\mu} = \frac{1}{2} \ln \left( \frac{1}{2\pi\sigma^2} \right)$$

$$\ln p_s = \frac{1}{2} \ln \left( \frac{1}{2\pi\sigma^2} \right) - \frac{1}{2} \frac{1}{\sigma^2} (s - \mu)^2 + \dots$$

$$p_s \approx \exp \left( \ln \left( \frac{1}{\sqrt{\frac{1}{2\pi\sigma^2}}} \right) - \frac{(s - \mu)^2}{2\sigma^2} \right)$$

$$p(s)ds = P(\text{de } s \text{ estar entre } s \text{ e } s + ds) \Rightarrow p(s)[(s+1) - s] = p(s) = p_s$$

$$p(s) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(s-\mu)^2}{2\sigma^2}}$$

# Desigualdade de Chebyshev

---

Seja  $x$  uma v.a. com valor médio  $\mu = E(X)$  e  $\varepsilon > 0$  um número positivo qualquer. Então

$$P(|X - \mu| \geq \varepsilon) \leq \frac{\text{Var} (X)}{\varepsilon^2}$$

**Prova:**  $P(|X - \mu| \geq \varepsilon) = \sum_{|x_i - \mu| \geq \varepsilon} P(x_i)$  (A prova é semelhante no caso continuo)

$$\sum_{x_i} (x_i - \mu)^2 P(x_i) = \text{Var} (X)$$

$$\sum_{|x_i - \mu| \geq \varepsilon} (x_i - \mu)^2 P(x_i) \leq$$

$$\sum_{|x_i - \mu| \geq \varepsilon} \varepsilon^2 P(x_i) \leq$$

$$\varepsilon^2 \sum_{|x_i - \mu| \geq \varepsilon} P(x_i) \leq$$

$$\varepsilon^2 P(|X - \mu| \geq \varepsilon) \leq$$

Portanto  $P(|X - \mu| \geq \varepsilon) \leq \frac{\text{Var} (X)}{\varepsilon^2}$

# *Lei dos grandes números ou das médias*

---

Sejam  $X_1, X_2, \dots, X_n$  observações independentes com valor esperado  $E(X_j) = \mu$  e variância  $\text{Var}(X) = \sigma^2$ . Seja  $S_n = X_1 + X_2 + \dots + X_n$ . Então para qualquer  $\varepsilon > 0$ ,

$$P\left(\left|\frac{S_n}{n} - \mu\right| \geq \varepsilon\right) \rightarrow 0 \text{ com } n \rightarrow \infty.$$

Equivalentemente:  $P\left(\left|\frac{S_n}{n} - \mu\right| < \varepsilon\right) \rightarrow 1 \text{ com } n \rightarrow \infty$

**Prova:** Uma vez que  $X_1, X_2, \dots, X_n$  são independentes e possuem a mesma distribuição, temos que:

$$\text{Var}(S_n) = n\sigma^2 \quad \text{e} \quad \text{Var}\left(\frac{S_n}{n}\right) = \frac{\sigma^2}{n}.$$

Pela desigualdade de Chebyshev:  $P(|X - \mu| \geq \varepsilon) \leq \frac{\sigma^2}{n\varepsilon}$

Portanto para um dado  $\varepsilon > 0$ :  $P\left(\left|\frac{S_n}{n} - \mu\right| \geq \varepsilon\right) \rightarrow 0 \text{ com } n \rightarrow \infty$

□ QED (*quod erat demonstrandum*).

# *Observações dos lançamentos de uma moeda*

---

## Observações de Bernoulli

Seja  $p$  a probabilidade de obtermos cara.

Seja  $X_j = 1$  no caso de sucesso na obtenção de cara e  $X_j = 0$  no caso oposto.

Então  $S_n = X_1 + X_2 + \dots + X_n$  é o número de sucessos em  $n$  observações.

$$\mu = E(X_j) = 1p + 0(1 - p) = p$$

De acordo com a lei dos grandes números:  $P\left(\left|\frac{S_n}{n} - \mu\right| \geq \varepsilon\right) \rightarrow 0$  com  $n \rightarrow \infty$

A firmação acima diz que, em um número  $n$  grande de experimentos podemos esperar que a proporção de vezes que o evento cara irá ocorrer é próximo de  $p$ .

Isto mostra que nosso modelo matemático de probabilidade concorda com nossa interpretação de frequência da probabilidade.

# Teorema do limite central

---

Se  $S_N$  é a soma de  $N$  v.a. mutuamente independentes então a função de distribuição de  $S_N$ , com  $N \rightarrow \infty$ , é bem aproximada pela função de densidade Gaussiana (normal)

$$f_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Vamos discutir este teorema apenas como aplicado a observações de Bernoulli.

Caso geral é assunto para um curso de teoria da probabilidade.

Considere observações de Bernoulli com probabilidade  $p$  de sucesso em cada experimento.

Seja  $X_i = 1$  ou  $-1$  respectivamente se o  $i$ -ésimo evento é um sucesso ou um fracasso.

$$S_N = X_1 + X_2 + \cdots + X_N,$$

é a diferença entre o número de sucessos e fracassos — o excesso de spin ( $2s$ ).

Sabemos que  $s$  ou  $\frac{S_N}{2}$  possui como sua distribuição a distribuição binomial de probabilidades.

Portanto como já vimos se  $N \rightarrow \infty$  esta distribuição é bem aproximada pela distribuição Gaussiana.