

Concentração de Medida

Thiago Rodrigo Ramos

28 de dezembro de 2024

Sumário

1	Introdução às desigualdades de concentração	2
1.1	Markov e seus amigos	2
1.2	Variáveis sub-gaussianas	4
1.3	Desigualdade de Hoeffding	7
2	Estimando a variância	9
2.1	Efron-Stein	9
2.2	Cotas exponenciais via Efron-Stein	12
3	Teoria da informação	14
3.1	Entropia de Shannon	14
A	Desigualdades básicas	15
A.1	Fatorial	15
B	Convexidade	15
B.1	Jensen	15

1 Introdução às desigualdades de concentração

Baseado em [Boucheron et al., 2013].

1.1 Markov e seus amigos

Teorema 1 (Desigualdade de Markov). *Seja X uma variável aleatória não-negativa. Então*

$$\mathbb{P}\{X \geq t\} \leq \frac{\mathbb{E}[X]}{t}.$$

Demonstração. Usando o fato que $X \geq 0$, temos que:

$$\begin{aligned} \mathbb{E}[X] &= \mathbb{E}[X \cdot \mathbb{I}\{X \geq t\}] + \mathbb{E}[X \cdot \mathbb{I}\{X < t\}] \\ &\geq t \cdot \mathbb{P}\{X \geq t\} + 0. \end{aligned}$$

□

Note que dado qualquer função não-decrescente e positiva ϕ , então pela desigualdade de Markov,

$$\mathbb{P}\{X \geq t\} \leq \mathbb{P}\{\phi(X) \geq \phi(t)\} \leq \frac{\mathbb{E}[\phi(X)]}{\phi(t)}.$$

De fato, considerando $\phi : x \mapsto x^2$, conseguimos o seguinte resultado.

Corolário 1 (Desigualdade de Chebyshev). *Dado uma variável aleatória qualquer X , temos que*

$$\mathbb{P}\{|X - \mathbb{E}[X]| \geq t\} \leq \frac{\text{Var}[X]}{t^2}.$$

Exemplo 1. *Sejam $\{X_i\}_{i=1}^n$ v.a. i.i.d. com média μ e variância σ^2 . Então para qualquer $t > 0$, por Chebyshev:*

$$\mathbb{P}\left\{\frac{1}{n} \left| \sum_{i=1}^n X_i - \mu \right| \geq t\right\} \leq \frac{n\sigma^2}{n^2 t^2} \rightarrow_n 0,$$

provando a uma versão da lei fraca dos grandes números.

Uma outra escolha natural para aplicarmos Markov é a função $\phi : x \mapsto e^{\lambda x}$ para algum $\lambda > 0$.

Corolário 2 (Desigualdade de Chernoff). *Dado uma variável aleatória qualquer X , temos que*

$$\mathbb{P}\{X \geq t\} \leq e^{-\lambda t} \mathbb{E}\left[e^{\lambda X}\right]. \quad (1)$$

TODO: Falar que o ótimo não é atingido por Chernoff, mas sim por algum momento (ex. 2.5).

Note que o que aparece do lado direito na desigualdade de Chernoff é algo que depende da função geradora de momento de X , dada por $\mathbb{E}[e^{\lambda X}]$. Por questões que ficarão mais claras no futuro, vamos reescrever a expressão 1 da seguinte forma:

$$\mathbb{P}\{X \geq t\} \leq e^{-\lambda t} \mathbb{E}[e^{\lambda X}] = e^{-(\lambda t - \psi_X(\lambda))},$$

onde $\psi_X(\lambda) = \log(\mathbb{E}[e^{\lambda X}])$.

Perceba que a conclusão da desigualdade de Chernoff vale para qualquer $\lambda > 0$, portanto podemos minimizar o lado direito em λ e assim temos o seguinte

$$\mathbb{P}\{X \geq t\} \leq e^{-\psi_X^*(t)}, \quad (2)$$

onde

$$\psi_X^*(t) = \sup_{\lambda \geq 0} (\lambda t - \psi_X(\lambda)).$$

Além disso, como $\psi_X(0) = 0$ e em $\psi_X^*(t)$ tomamos o supremo sobre os $\lambda \geq 0$, é claro que $\psi_X^*(t) \geq 0$. A função ψ_X^* é conhecida como transformada de Crammér de X e mais geralmente se o supremo é sobre todos os valores de λ , é conhecida como Função Dual Fenchel-Legendre de ψ_X .

TODO: Explicar como generalizar para λ qualquer e falar da diferenciabilidade e convexidade.

Exemplo 2 (Distribuição Normal). Se $X \sim N(0, \sigma^2)$, é fácil mostrar que $M_X(\lambda) = e^{\lambda^2 \sigma^2 / 2}$, logo $\psi_X(\lambda) = \frac{\lambda^2 \sigma^2}{2}$ e

$$\psi_X^*(t) = \frac{t^2}{2\sigma^2}.$$

Logo, por Eq. 2, temos que

$$\mathbb{P}\{X \geq t\} \leq e^{-t^2 / (2\sigma^2)}.$$

De fato, esse limitante é o melhor possível a menos de uma constante. **TODO:** mostrar isso.

Exemplo 3 (Soma de i.i.d.). Sejam $\{X_i\}_{i=1}^n$ v.a. i.i.d. e defina $S_n = \sum_{i=1}^n X_i$. Então, $\mathbb{E}[e^{\lambda S_n}] = \prod_{i=1}^n \mathbb{E}[e^{\lambda X_i}] = M_X(\lambda)^n$ e portanto $\psi_{S_n}(\lambda) = n\psi_X(\lambda)$ e dessa forma

$$\psi_{S_n}^*(t) = \sup_{\lambda > 0} (\lambda t - n\psi_X(\lambda)) = n \sup_{\lambda > 0} (\lambda \frac{t}{n} - \psi_X(\lambda)) = n\psi_X^*(t/n).$$

Por exemplo, se $X_i \sim N(0,1)$ então $\psi_{S_n}^* = n\psi_X^*(t/n) = n \frac{t^2}{2n^2}$ e então

$$\mathbb{P}\{S_n \geq t\} \leq e^{-t^2/(2n)}.$$

Podemos também considerar a probabilidade da soma ser maior que nt e concluir que

$$\mathbb{P}\left\{\frac{S_n}{n} \geq t\right\} \leq e^{-nt^2/2}.$$

1.2 Variáveis sub-gaussianas

Dizemos que uma v.a. X com $\mathbb{E}[X] = 0$ é sub-gaussiana se sua função geradora de momento é limitada pela função geradora de momento de uma v.a. normal com variância v^2 , ou seja,

$$\psi_X(\lambda) \leq \frac{\lambda^2 v^2}{2}, \quad \lambda \in \mathbb{R}. \quad (3)$$

TODO: falar que precisa ser centrada

Note que por Chernoff, se X é centrada e subgaussiana, então

$$\mathbb{P}\{X \geq t\} \leq e^{-x^2/(2v^2)},$$

já que essa se comporta basicamente como uma normal com variância v^2 (Exemplo 1.1). A partir desse fato, conseguimos caracterizar as variáveis sub-gaussianas de outras formas.

Teorema 2. *Seja X uma v.a. com $\mathbb{E}[X] = 0$ e suponha que para algum v^2 ,*

$$\max\{\mathbb{P}\{X > t\}, \mathbb{P}\{-X > t\}\} \leq e^{-x^2/(2v^2)},$$

então para qualquer $q \geq 1$,

$$\mathbb{E}[X^{2q}] \leq 2q!(2v^2)^q \leq q!(4v^2)^q.$$

Reciprocamente, se existir constante C tal que

$$\mathbb{E}[X^{2q}] \leq q!C^q,$$

então X é sub-gaussiana com $v^2 = 4C$.

Observação 1 (Momentos de uma Normal e fatorial duplo). *Seja X uma v.a. com distribuição Normal de média 0 e variância σ^2 . Então sabemos que*

$$\mathbb{E}[X^{2q}] = \sigma^{2q}(2q-1)!!,$$

onde $n!!$ é o fatorial duplo, isto é, $n!!$ é o produto de todos os números menores que n que possuem a mesma paridade.

Note que

$$n!! = \frac{(n+1)!}{(n+1)!!}$$

e que

$$(2q)!! = \prod_{i=0}^{q-1} (2q-2i) = 2^q \prod_{i=0}^{q-1} (q-i) = 2^q q!$$

Portanto,

$$(2q-1)!! = \frac{(2q)!}{(2q)!!} = \frac{(2q)!}{2^q q!}.$$

Dessa forma, temos o seguinte

$$\begin{aligned} \mathbb{E}[X^{2q}] &= \sigma^{2q} (2q-1)!! \\ &= \sigma^{2q} \frac{(2q)!}{2^q q!}. \end{aligned}$$

Agora note que,

$$\frac{(2q)!}{q!} = \prod_{i=1}^q (q+i) \geq \prod_{i=1}^q (i+i) = 2^q q!.$$

E portanto,

$$\begin{aligned} \mathbb{E}[X^{2q}] &= \sigma^{2q} (2q-1)!! \\ &= \sigma^{2q} \frac{(2q)!}{2^q q!} \\ &\geq \sigma^{2q} \frac{1}{2^q} 2^q q! \\ &= (\sigma^2)^q q!. \end{aligned}$$

Logo, o Teorema 2 nos diz é que podemos caracterizar uma v.a. sub-gaussiana comparando o seu limitate do tipo Chernoff com o de uma Normal, ou comparando os seus momentos pares com o de uma normal.

Prova do Teorema 2. O argumento que vamos utilizar é bem comum nesse tipo de prova. Vamos assumir por simplicidade que $v = 1$. Note que

$$\mathbb{E}[X^{2q}] = 2q \int_0^\infty x^{2q-1} \mathbb{P}\{|X| > x\} dx,$$

fazendo a mudança de variável $u^{2q} = x$. Dessa forma

$$\mathbb{E}[X^{2q}] \leq 4q \int_0^\infty x^{2q-1} e^{-x^2/2} dx,$$

onde um fator de 2 aparece pelo union bound de $\{|X| > t\} = \{X > t\} \cup \{-X > t\}$.

Fazendo a mudança de variável $2u = x^2$, temos que

$$\begin{aligned}
\mathbb{E} [X^{2q}] &\leq 4q \int_0^\infty x^{2q-1} e^{-x^2/2} dx \\
&= 4q \int_0^\infty (2x)^{q-1} e^{-x} dx \\
&= q2^{q+1} \int_0^\infty x^{q-1} e^{-x} dx \\
&= q2^{q+1} \Gamma(q-1+1) \\
&= 2q!(2v^2)^q.
\end{aligned}$$

Reciprocamente, suponha que $\mathbb{E} [X^{2q}] \leq q!C^q$. Tome X' uma cópia i.i.d. de X . Então,

$$\mathbb{E} [e^{\lambda X}] \mathbb{E} [e^{-\lambda X}] = \mathbb{E} [e^{\lambda(X-X')}] = \sum_{i=0}^{\infty} \frac{\lambda^{2q} \mathbb{E} [(X-X')^{2q}]}{(2q)!},$$

já que se $Z = X - X'$, note que $Z \sim -Z$ e como $x \mapsto x^{2q-1}$ são funções ímpares, temos que $\mathbb{E} [Z^{2q-1}] = \mathbb{E} [(-Z)^{2q-1}] = -\mathbb{E} [Z^{2q-1}]$ e portanto $\mathbb{E} [Z^{2q-1}] = 0$.

Como $g(x) = x^{2q}$ é convexa, temos que $g(x/2 - y/2) \leq g(x)/2 + g(-y)/2$, isto é,

$$\frac{1}{2^{2q}}(x-y)^{2q} \leq \frac{1}{2}(x^{2q} + y^{2q}),$$

dessa forma, temos que

$$\begin{aligned}
\mathbb{E} [e^{\lambda X}] \mathbb{E} [e^{-\lambda X}] &= \sum_{i=0}^{\infty} \frac{\lambda^{2q} \mathbb{E} [(X-X')^{2q}]}{(2q)!} \\
&\leq \sum_{i=0}^{\infty} \frac{\lambda^{2q} 2^{2q} \mathbb{E} [X^{2q}]}{(2q)!} \\
&\leq \sum_{i=0}^{\infty} \lambda^{2q} 2^{2q} C^q \frac{q!}{(2q)!} \\
&\leq \sum_{i=0}^{\infty} \lambda^{2q} 2^{2q} C^q \frac{1}{2^q q!} \\
&\leq \sum_{i=0}^{\infty} \lambda^{2q} 2^q C^q \frac{1}{q!} \\
&\leq \sum_{i=0}^{\infty} \frac{(2C\lambda^2)^q}{q!}.
\end{aligned}$$

Ou seja,

$$\mathbb{E} [e^{\lambda X}] \leq e^{2C\lambda^2} \frac{1}{\mathbb{E} [e^{-\lambda X}]} \leq e^{2C\lambda^2},$$

já que $\mathbb{E}[X] = 0$ e portanto por Jensen temos que $\mathbb{E}[e^{-\lambda X}] \geq e^{-\lambda \mathbb{E}[X]} = 1$. \square

A hipótese de sub-gaussianidade é interessante para generalizar resultados que em geral valem para v.a. normais. A seguir vamos provar a desigualdade maximal.

Teorema 3 (Desigualdade Maximal). *Sejam $\{X_i\}_{i=1}^n$ v.a. i.i.d., centradas com sub-gaussianas com constante v^2 . Então*

$$\mathbb{E} \left[\max_{i=1, \dots, n} X_i \right] \leq \sqrt{v^2 n \log(n)}$$

Demonstração. Por Jensen, e o fato de que $x \mapsto e^{\lambda x}$ é crescente para $\lambda > 0$ temos

$$\begin{aligned} e^{\lambda \mathbb{E}[\max_{i=1, \dots, n} X_i]} &\leq \mathbb{E} \left[e^{\lambda \max_{i=1, \dots, n} X_i} \right] \\ &= \mathbb{E} \left[\max_{i=1, \dots, n} e^{\lambda X_i} \right] \\ &\leq \sum_{i=1}^n \mathbb{E} \left[e^{\lambda X_i} \right]. \end{aligned}$$

Como as v.a. são sub-gaussianas, temos

$$\begin{aligned} e^{\lambda \mathbb{E}[\max_{i=1, \dots, n} X_i]} &\leq \sum_{i=1}^n \mathbb{E} \left[e^{\lambda X_i} \right] \\ &\leq n e^{\lambda^2 v^2 / 2}. \end{aligned}$$

Dessa forma, temos o seguinte

$$\mathbb{E} \left[\max_{i=1, \dots, n} X_i \right] \leq \frac{1}{\lambda} \left(\log n + \frac{\lambda^2 v^2}{2} \right),$$

que é minimizado quando $\lambda = \sqrt{2(\log n)/v^2}$ o que nos dá

$$\mathbb{E} \left[\max_{i=1, \dots, n} X_i \right] \leq \sqrt{2v^2 \log n}.$$

\square

1.3 Desigualdade de Hoeffding

Na seção anterior aprendemos sobre v.a. sub-gaussianas, agora vamos mostrar que toda v.a. limitada é sub-gaussiana. Alguns elementos da prova do teorema serão úteis no futuro.

Teorema 4 (Lema de Hoeffding). *Seja X uma v.a. com $\mathbb{E}[X] = 0$ e tal que $X \in [a, b]$. Então temos que $\psi_X(\lambda) \leq \frac{\lambda^2(b-a)^2}{4}$.*

Demonstração. Note que a distância de X metade do intervalo (a, b) é sempre menor que a metade do intervalo (a, b) , isto é,

$$\left| X - \frac{b+a}{2} \right| \leq \frac{b-a}{2}.$$

Dessa forma temos que $\text{Var}[X] = \text{Var}\left[X - \frac{b+a}{2}\right] \leq \frac{(b-a)^2}{4}$.

Agora, seja dP a distribuição de X e considere a distribuição $dP_\lambda(x) = e^{-(\psi_X(\lambda) - \lambda x)} dP(x)$. Note que

$$\int dP_\lambda(x) = \int e^{-(\psi_X(\lambda) - \lambda x)} dP(x) = \mathbb{E}_P[e^{\lambda X}] / \mathbb{E}_P[e^{\lambda X}] = 1$$

logo, dP_λ é de fato uma distribuição.

Agora note que

$$\begin{aligned} \psi''(\lambda) &= \left(\log(\mathbb{E}[e^{\lambda X}]) \right)'' \\ &= \left(\frac{\mathbb{E}[Xe^{\lambda X}]}{\mathbb{E}[e^{\lambda X}]} \right)' \\ &= \frac{\mathbb{E}[X^2 e^{\lambda X}] \mathbb{E}[e^{\lambda X}] - (\mathbb{E}[Xe^{\lambda X}])^2}{\mathbb{E}[e^{\lambda X}]^2} \\ &= \frac{\mathbb{E}[X^2 e^{\lambda X}]}{\mathbb{E}[e^{\lambda X}]} - \left(\frac{\mathbb{E}[Xe^{\lambda X}]}{\mathbb{E}[e^{\lambda X}]} \right)^2 \\ &= \mathbb{E}_{P_\lambda}[X^2] - \mathbb{E}_{P_\lambda}[X]^2 \\ &= \text{Var}_{P_\lambda}[X] \\ &\leq \frac{(b-a)^2}{4}. \end{aligned}$$

Além disso, $\psi(0) = 0$ e $\psi'(0) = \mathbb{E}[X] = 0$. Logo

$$\psi(\lambda) = \psi(0) + \psi'(0)\lambda + \frac{\lambda^2}{2}\psi''(\theta) \leq (b-a)^2/4,$$

onde $\theta \in [0, \lambda]$. □

Na prova acima, perceba que se $\mathbb{E}[X] = 0$ então limitar $\psi''(\lambda)$ é suficiente para limitar $\psi(\lambda)$, isso nos sera útil no futuro.

2 Estimando a variância

2.1 Efron-Stein

Nessa capítulo vamos estudar v.a. da forma $Z = f(X_1, \dots, X_n)$ onde X_i são v.a. independentes e $f : \mathcal{X} \rightarrow \mathbb{R}$.

Sabemos que no caso de soma de v.a.s independentes, $S_n = X_1 + \dots + X_n$, temos que

$$\text{Var} [S_n] = \sum_{i=1}^n \text{Var} [X_i],$$

isto é, a variância da função soma é aditiva. Nessa seção o nosso objetivo é encontrar algo parecido para funções quaisquer f .

Antes de continuarmos, vamos introduzir a seguinte notação para a esperança condicional

$$\mathbb{E}_{a:b} [Z] = \mathbb{E} [Z | X_1, \dots, X_{a-1}, X_{b+1}, \dots, X_n], \quad (4)$$

isto é, o operador $\mathbb{E}_{a:b} [\cdot]$ integra as variáveis entre a e b e o resto é fixo.

Dessa forma temos que

$$Z - \mathbb{E} [Z] = \sum_{i=1}^n \Delta_i,$$

onde $\Delta_i = \mathbb{E}_{i+1:n} [Z] - \mathbb{E}_{i:n} [Z]$. Perceba que Δ_j já teve todas as variáveis depois de j integradas e portanto só sobrou aleatoriedade antes de j . Portanto,

$$\begin{aligned} \text{Var} [Z] &= \mathbb{E} \left[\left(\sum_{i=1}^n \Delta_i \right)^2 \right] \\ &= \mathbb{E} \left[\sum_{i,j=1}^n \Delta_i \Delta_j \right] \\ &= \mathbb{E} \left[\sum_i \Delta_i^2 + 2 \sum_{i < j} \Delta_i \Delta_j \right] \\ &= \sum_i \mathbb{E} [\Delta_i^2] + 2 \sum_{i < j} \mathbb{E} [\Delta_i \Delta_j] \\ &= \sum_i \mathbb{E} [\Delta_i^2] + 2 \sum_{i < j} \mathbb{E} [\mathbb{E}_{i+1:n} [\Delta_i \Delta_j]]. \end{aligned}$$

Note que $\mathbb{E}_{i+1:n} [\Delta_i \Delta_j] = \Delta_i \mathbb{E}_{i+1:n} [\Delta_j] = \Delta_i \cdot 0$.

Concluimos então que

$$\text{Var} [Z] = \sum_{i=1}^n \mathbb{E} [\Delta_i^2]. \quad (5)$$

Agora note que $\mathbb{E}_{i+1:n} [\mathbb{E}_{i:i} [Z]] = \mathbb{E}_{i:n} [Z]$ e portanto

$$\Delta_i^2 = (\mathbb{E}_{i+1:n} [Z - \mathbb{E}_{i:i} [Z]])^2.$$

Por Jensen, temos então que

$$\Delta_i^2 = (\mathbb{E}_{i+1:n} [Z - \mathbb{E}_{i:i} [Z]])^2 \leq \mathbb{E}_{i+1:n} [(Z - \mathbb{E}_{i:i} [Z])^2],$$

concluindo então que

$$\begin{aligned} \mathbb{E} [\Delta_i^2] &\leq \mathbb{E} [(Z - \mathbb{E}_{i:i} [Z])^2] = \mathbb{E} [\mathbb{E}_{i:i} [(Z - \mathbb{E}_{i:i} [Z])^2]] \\ &= \mathbb{E} [\text{Var}_{i:i} [Z]]. \end{aligned}$$

Juntando isso com Eq. 5, temos o que é conhecido com desigualdade de Efron-Stein:

$$\text{Var} [Z] \leq \sum_{i=1}^n \mathbb{E} [(Z - \mathbb{E}_{i:i} [Z])^2] = \sum_{i=1}^n \mathbb{E} [\text{Var}_{i:i} [Z]].$$

Essas identidades nos dizem que para estimar a variância de Z , basta estudarmos como f se comporta elemento a elemento.

Além disso, qualquer propriedade que conseguimos derivar para uma coordenada de $f(X_1, \dots, X_n)$, é automaticamente estendida para a variância de Z . Por exemplo, pela caracterização da esperança como o minimizador do erro quadrático, também temos que

$$\text{Var} [Z] \leq \sum_{i=1}^n \mathbb{E} [\mathbb{E}_{i:i} [Z - \tilde{Z}_i]^2] = \sum_{i=1}^n \mathbb{E} [(Z - \tilde{Z}_i)^2],$$

para qualquer \tilde{Z}_i mensurável no produto ignorando i , sendo uma igualdade com a variância que encontramos anteriormente quando $\tilde{Z}_i = \mathbb{E}_{i:i} [Z]$. Outro exemplo: sabemos que se X, X' são cópias i.i.d., então

$$\mathbb{E} [X - X']^2 = \mathbb{E} [X - \mathbb{E} [X] - (X' - \mathbb{E} [X'])]^2 = 2\text{Var} [X].$$

Logo, temos que

$$\mathbb{E} [\text{Var}_{i:i} [Z]] = \frac{1}{2} \mathbb{E} [\mathbb{E}_{i:i} [Z - Z'_i]^2]$$

onde Z'_i é uma cópia de Z mas com coordenada X_i trocada por uma cópia i.i.d. X'_i . E portanto, também temos que

$$\begin{aligned} \text{Var} [Z] &\leq \frac{1}{2} \sum_{i=1}^n \mathbb{E} [\mathbb{E}_{i:i} [Z - Z'_i]^2] \\ &= \sum_{i=1}^n \mathbb{E} [\mathbb{E}_{i:i} [Z - Z'_i]_+^2] \\ &= \sum_{i=1}^n \mathbb{E} [\mathbb{E}_{i:i} [Z - Z'_i]_-^2], \end{aligned}$$

onde usamos o fato de que $(Z - Z')_+ \sim (Z' - Z)_+ = (Z - Z')_-$ e $Z_+ Z_- = 0$.

Exemplo 4 (Diferenças limitadas). *Vamos estudar o que acontece quando a função f satisfaz uma propriedade muito comum. Dizemos que $f : \mathcal{X} \rightarrow \mathbb{R}$ satisfazer a propriedade das diferenças limitadas se existem c_1, \dots, c_n positivos tal que:*

$$\sup_{x_1, x'_1, \dots, x_n, x'_n} |f(x_1, \dots, x_i, \dots, x_n) - f(x_1, \dots, x'_i, \dots, x_n)| \leq c_i,$$

isto é, se fixado todas as coordenadas, exceto a i -ésima, então f não muda mais que c_i .

Usando o mesmo argumento que a distância de Z até o ponto médio dos extremos do intervalo que está contigo é no máximo metade do tamanho do intervalo, isto é,

$$|Z - (b + a)/2| \leq (b - a)/2$$

onde $b = \sup_{x'_i} f(X_1, \dots, x'_i, \dots, X_n)$ e $a = \inf_{x'_i} f(X_1, \dots, x'_i, \dots, X_n)$, temos que

$$\text{Var}[Z] \leq \sum_{i=1}^n \mathbb{E}[\text{Var}_{i:i}[Z]] \leq \sum_{i=1}^n (b - a)^2/4 \leq \sum_{i=1}^n c_i^2/4.$$

Exemplo 5 (Maior autovalor de matrizes aleatórias). *Seja A uma matriz simétrica com coordenadas $X_{i,j}$ i.i.d. e $|X_{i,j}| \leq 1$, estamos interessados em estudar $Z = f(A) = \lambda_1$ onde λ_1 é seu maior autovalor. Sabemos que*

$$\lambda_1 = \sup_{\|u\|=1} u^t A u.$$

Além disso, se v é autovetor correspondente à λ_1 , então

$$v^t A v = \lambda_1 v^t v = \lambda_1$$

pela ortonormalidade da decomposição de matrizes simétricas.

Vamos tentar estudar a variância de Z , para isso note que se $A'_{i,j}$ é uma cópia de A com a entrada $X'_{i,j}$ sendo uma cópia i.i.d. de $X_{i,j}$, então para um v qualquer, temos que

$$\begin{aligned} f(A) - f(A'_{i,j}) &= v^t A v - \sup_{\|u\|=1} u^t A'_{i,j} u \\ &\leq v^t A v - v^t A'_{i,j} v \\ &= v^t (A - A'_{i,j}) v \\ &= v^t ((e_i e_j^t + e_j e_i^t)(X_{ij} - X'_{ij})) v \\ &= v^t ((e_i e_j^t + e_j e_i^t)) v (X_{ij} - X'_{ij}) \\ &= 2v_i v_j (X_{ij} - X'_{ij}) \\ &\leq 4v_i v_j. \end{aligned}$$

Dessa forma, por Efron-Stein e o fato que $\|v\| = 1$,

$$\text{Var}[f(A)] \leq \sum_{i \leq j} \mathbb{E} \left[(f(A) - f(A'_{ij}))_+^2 \right] \leq \sum_{i \leq j} 16v_i^2 v_j^2 = 16.$$

TODO: Para tomarmos o quadrado dos dois lados, precisamos garantir que as coisas são positivas, por isso é importante truncar positivamente o lado esquerdo para garantir que é positivo!!! Isso corrige o bound

Exemplo 6 (Desigualdade de Poincaré). Suponha que temos uma função contínua $f : [0, 1]^n \rightarrow \mathbb{R}$ que é convexa coordenada a coordenada e tem derivadas parciais.

Por convexidade temos $f'(x)(x - y) > f(x) - f(y)$, portanto, contanto que $f(x) - f(y) > 0$, teremos que $f'(x)^2(x - y)^2 > (f(x) - f(y))^2$.

Considere então $Z_i = \min_{x'_i} f(X_1, \dots, x_i, \dots, X_n)$ e X_i^* o valor que atinge esse mínimo, que existe por compacidade e continuidade. Então,

$$\begin{aligned} (Z - Z_i)^2 &= (f(X_1, \dots, X_i, \dots, X_n) - f(X_1, \dots, X'_i, \dots, X_n))^2 \\ &\leq \partial_i f(X)^2 (X_i - X'_i)^2 \\ &\leq \partial_i f(X)^2. \end{aligned}$$

Dessa forma

$$\text{Var}[Z] \leq \sum_{i=1}^n \mathbb{E} [(Z - Z_i)^2] \leq \sum_{i=1}^n \partial_i f(X)^2 = \|\nabla f(X)\|^2.$$

2.2 Cotas exponenciais via Efron-Stein

Vamos apresentar agora um truque para conseguirmos cotas exponenciais utilizando as cotas da variância que temos via Efron-Stein. Para isso, primeiro vamos definir os quantis

$$Q_\alpha = \inf\{z : \mathbb{P}\{Z \leq z\} \geq \alpha\}.$$

Considere a seguinte função

$$g_{a,b}(x) = \begin{cases} b & \text{se } f(x) \geq b \\ a & \text{se } f(x) \leq a \\ f(x) & \text{se } a < f(x) < b \end{cases}$$

Note que, se $a \geq Mf(X)$, onde $M = Q_{1/2}$ é a mediana, temos

$$\begin{aligned}
 \mathbb{E}[g_{a,b}(X)] &= b\mathbb{E}[\mathbb{I}\{f(X) \geq b\}] + a\mathbb{P}\{f(X) \leq a\} + \mathbb{E}[f(X)\mathbb{I}\{a < f(X) < b\}] \\
 &\leq b\mathbb{E}[\mathbb{I}\{f(X) \geq b\}] + a\mathbb{P}\{f(X) \leq a\} + b\mathbb{E}[\mathbb{I}\{a < f(X) < b\}] \\
 &= a\mathbb{P}\{f(X) \leq a\} + b\mathbb{P}\{a < f(X)\} \\
 &= a\mathbb{P}\{f(X) \leq a\} + b(1 - \mathbb{P}\{f(X) \leq a\}) \\
 &= b + (b - a)(-\mathbb{P}\{f(X) \leq a\}) \\
 &\leq b + (b - a)(-\mathbb{P}\{f(X) \leq MZ\}) \\
 &\leq b - (b - a)/2 \\
 &= (b + a)/2,
 \end{aligned}$$

já que $(b - a) > 0$ e $\mathbb{P}\{f(X) \leq a\} \geq \mathbb{P}\{f(X) \leq MZ\} \geq 1/2$.

Isso nos diz que

$$g_{ab}(X) - \mathbb{E}[g_{ab}(X)] \geq g_{ab}(X) - (b + a)/2.$$

Note condicionado à $\{g_{ab}(X) = b\}$ o lado direito é positivo para podermos tomar o quadrado dos dois lados. Logo,

$$\begin{aligned}
 \mathbb{E}[(g_{ab}(X) - \mathbb{E}[g_{ab}(X)])^2] &\geq \mathbb{E}[(g_{ab}(X) - \mathbb{E}[g_{ab}(X)])^2\mathbb{I}\{g_{ab}(X) = b\}] \\
 &= (b - (a + b)/2)^2\mathbb{P}\{g_{ab}(X) = b\} \\
 &= \mathbb{P}\{f(X) \geq b\}(b - a)/4.
 \end{aligned}$$

Concluindo então que

$$\text{Var}[g_{ab}(X)] \geq \mathbb{P}\{f(X) \geq b\}(b - a)/4.$$

Agora vamos achar uma cota superior usando Efron-Stein. Para uma cópia independente X'_i , note que $g_{ab}(X) - g_{ab}(X'_i)$ é não nula apenas

TODO: terminar isso

3 Teoria da informação

Na seção anterior, falamos sobre a sub-aditividade da variância. Nessa seção, vamos tentar estender aquela ideia para outra estatística diferente da variância.

3.1 Entropia de Shannon

Para começarmos, vamos considerar X uma v.a. com distribuição p discreta. Definimos a entropia de Shannon de X , $H(X)$, como

$$H(X) = -\sum_x p(x) \log p(x) = \mathbb{E}_X [-\log p(X)] \geq 0.$$

Uma quantidade relacionada com a entropia é a divergência de Kullback-Leibler definida como

$$D(P\|Q) = \sum_x p(x) \log \left(\frac{p(x)}{q(x)} \right) = -(\mathbb{E}_P [\log q(X)] - \mathbb{E}_P [\log p(X)]).$$

Intuitivamente, $D(P\|Q)$ funciona como uma distância entre a distribuição Q da P , ou então, o quanto a gente perde por usar Q no lugar de P . Note que, usando o fato de $\log x \leq x - 1$,

$$\begin{aligned} D(P\|Q) &= -\sum_x p(x) \log \left(\frac{q(x)}{p(x)} \right) \\ &\leq -\sum_x p(x) \left(\frac{q(x)}{p(x)} - 1 \right) \\ &= -\sum_x q(x) + \sum_x p(x) \\ &= 0. \end{aligned}$$

Logo $D(P\|Q) \geq 0$ o que nos diz que $-\mathbb{E}_P [\log q(X)] \geq -\mathbb{E}_P [\log p(X)]$, ou seja, usar Q no lugar de P numa amostra vinda de P tem uma quantidade tipo entropia sempre maior.

A Desigualdades básicas

A.1 Fatorial

TODO: Falar de $2p!$ e $2p!/p!$

B Convexidade

B.1 Jensen

Referências

[Boucheron et al., 2013] Boucheron, S., Lugosi, G., and Massart, P. (2013). *Concentration Inequalities: A Nonasymptotic Theory of Independence*. Oxford University Press. [2](#)