

# Inferência para CS Seleção de Modelos

Renato Martins Assunção

DCC - UFMG

2025

# Entropy

- Imagine a sequence of independent symbol emissions from a source.
- Symbols  $X$  are selected randomly from a finite dictionary according to a probability distribution  $p(x)$ .
- Each symbol is represented with a 0-1 string
- Prefix code is used:
  - No codeword appears at the beginning (prefix) of any other codeword.
  - Avoid ambiguity when decoding
  - Instantaneous decoding: no need to wait to see the next symbol.
- We want to use the shortest possible code to save on transmission.
- Can you find this shortest code?

# Entropy

- Yes, we can.
- Shannon's Mater's thesis (1937)
- For a discrete random variable  $X$ , the Shannon entropy is defined as:


$$H(X) = - \sum_x p(x) \log_2(p(x))$$

- The entropy of a probability distribution is the minimum expected number of bits required to encode symbols drawn from that distribution.
- It is not the minimum number of bits needed for each individual symbol.
- It is the minimum average (expected) number of bits per symbol, over many symbols, when using the best possible encoding strategy.
- We will adopt a different approach

## Entropia de um evento

- Seja  $E$  um evento num certo espaço amostral.
- O evento  $E$  ocorre ou não ocorre em cada realização do experimento aleatório.
- Seja  $\mathbb{P}(E) \in [0, 1]$  a probabilidade da ocorrência de  $E$ .
- A entropia associada com a ocorrência do evento  $E$  mede o GRAU DE SURPRESA que a ocorrência de  $E$  acarreta.
- Surprise:  $-\log(\mathbb{P}(E))$ .
- Why???? In just few minutes...

Entropia de evento é  $-\log(p)$



# Log em que base?

- Qualquer uma.
- Como  $\log_a(x) = \log_a(b) \log_b(x)$  temos

$$\log_a(x) = c \log_b(x)$$

onde  $c = \log_a(b)$  é uma constante que depende apenas das duas bases, e não de  $x$ .

- Isto implica que a diferença absoluta de log's numa base  $a$  é igual à diferença na base  $b$  vezes uma constante

$$\log_a(x) - \log_a(y) = c (\log_b(x) - \log_b(y))$$

- E diferenças relativas são iguais nas duas bases

$$\frac{\log_a(x)}{\log_a(y)} = \frac{\log_b(x)}{\log_b(y)}$$

- A idéia é que muita ou pouca entropia numa base será também muita ou pouca entropia na outra base.

# Interpretação de entropia

- Seja  $a$  um inteiro entre 1 e 9. Temos

$$0 = \log_{10}(1) \leq \log_{10}(a) \leq \log_{10}(9) \approx 0.95$$

- Seja  $p = a.bcdef\dots 10^{-k}$  onde  $a$  é um inteiro entre 1 e 9.
- Tome entropia na base 10. Então

$$\begin{aligned}
 -\log_{10}(p) &= -\log_{10}(a.bcdef\dots 10^{-k}) \\
 &= -\log_{10}(a.bcdef\dots) - \log_{10}(10^{-k}) \\
 &= -\log_{10}(a.bcdef\dots) + k \\
 &\approx k
 \end{aligned}$$

- já que o primeiro termo é um valor entre 0 e -1 (ver 1a equação).
- Então: ENTROPIA de  $p$  é  $-\log_{10}(p)$  (aprox) o número de casas decimais antes do primeiro número significativo.

## Interpretação de entropia

- Se tomarmos entropia com logs na base 2 (isto é, entropia é  $-\log_2(p)$ ), então a entropia será aprox o número de bits iguais a zero na expansão de  $p$  na base 2 antes do primeiro bit significativo.
- Um indivíduo escolhe um número entre  $\{0, 1, 2, \dots, 9\}$
- Uma loteria sorteia um dos números da lista com igual probabilidade.
- A chance de acertar na loteria é  $p = 0.1$  com entropia (surpresa)  $-\log_{10}(p) = 1$ .
- Suponha agora que a lista de números seja  $\{0, 1, 2, \dots, 99\}$ .
- A entropia do evento acertar na nova loteria (surpresa) é  $-\log_{10}(0.01) = 2$ .
- Se a lista de números for  $\{0, 1, 2, \dots, 999\}$ .
- a entropia (surpresa) passa a ser  $-\log_{10}(0.001) = 3$ .

# Interpretação de entropia

- Incremento na surpresa é linear com diminuição multiplicativa da probabilidade.
- Incremento de surpresa de ganhar na loteria quando passo de probabilidade 0.1 para 0.01 é  $\Delta = 2 - 1 = 1$ .
- Incremento ao passar 0.01 para 0.001 é TAMBÉM  $\Delta = 3 - 2 = 1$ .
- De maneira geral:

$$-\log_{10} \left( \frac{p}{10^k} \right) = -\log_{10}(p) + k$$

- Dividir por  $10^k$  a chance faz aumentar a surpresa em  $k$  unidades.
- Surpresa (entropia) cresce linearmente com a ORDEM DE GRANDEZA (ou precisão) de  $p$ .

# Entropia tem de ser da forma $\log$

- Se entropia (surpresa) funciona desta forma, ela TEM DE SER da forma  $-\log(p)$ .
- Por quê?
- O que significa “funcionar desta forma” ??
- Seja  $S : [0, 1] \rightarrow [0, \infty)$  uma função matemática que visa capturar o sentido de surpresa.
- Queremos que  $S$  tenha as seguintes propriedades óbvias:
  - ①  $S(1) = 0$  (a ocorrência de um evento que tem chance 100% de ocorrência tem surpresa 0, nula).
  - ②  $S(0) = \infty$  (a ocorrência de um evento impossível traz surpresa infinita)
  - ③  $S(p)$  é decrescente em  $p$

## Propriedade adicional

- Vamos impor uma condição adicional em  $S(p)$ .
- A função  $S(p)$  deverá satisfazer a seguinte propriedade:

$$S(p_2p_1) - S(p_2) = S(p_3p_1) - S(p_3)$$

para todo  $p_1, p_2, p_3$  em  $[0, 1]$ .

- O que esta propriedade está dizendo?
- Tome o aumento de surpresa  $S(p_2p_1) - S(p_2)$  ao passar da ocorrência de um evento com probabilidade  $p_2$  para outro com probabilidade menor  $p_2p_1$ .
- Este aumento de surpresa é o mesmo se reduzimos a probabilidade  $p_3$  de um evento por  $p_1$  passando então a ter a probabilidade  $p_3p_1$ .

# Propriedade adicional

- Suponha

$$S(p_2p_1) - S(p_2) = S(p_3p_1) - S(p_3)$$

para todo  $p_1, p_2, p_3$  em  $[0, 1]$ .

- Por exemplo, ao passar de  $p_2 = 0.5$  para  $p_2p_1 = 0.5/5 = 0.1$  teremos certo aumento  $\Delta$  de surpresa.
- Este aumento  $\Delta$  de surpresa é o mesmo que temos ao passar de  $p_3 = 0.0003$  para  $p_3p_1 = 0.0003/5 = 0.00006$ .
- E isto vale para todo  $p_1, p_2, p_3$ .
- Este é o sentido desta propriedade adicional que queremos para a função surpresa.

## Teorema

- Uma função  $S$  com estas 4 propriedades só pode ser da forma  $S(p) = -c \log(p)$ , onde  $c$  é uma constante positiva qualquer.
- **PROVA:** Tome  $p_3 = 1$  na propriedade adicional.
- Como  $S(1) = 0$ , temos

$$S(p_2 p_1) - S(p_2) = S(p_3 p_1) - S(p_3) = S(p_1) - S(1) = S(p_1)$$

- e então

$$S(p_2 p_1) = S(p_2) + S(p_1)$$

- Isto é, a função  $S(p)$  deve transformar produtos em somas.
- A única função com esta propriedade é a função  $\log$
- Ver prova disso em livros de análise matemática.

# Surpresa acarretada pela ocorrência de v.a. $X$

- Suponha que  $X$  seja uma v.a. discreta com a seguinte distribuição:

Valores Possíveis	$x_1$	$x_2$	...	$x_M$
Probabilidades	$p(x_1)$	$p(x_2)$	...	$p(x_M)$
Surpresas	$-\log p(x_1)$	$-\log p(x_2)$	...	$-\log p(x_M)$

- Um valor aleatório de  $X$  é selecionado com as probabilidades acima.
- Suponha que o valor instanciado de  $X$  seja  $x_i$ .
- Se o valor  $x_i$  for raro, a surpresa  $-\log p(x_i)$  ocasionada por sua ocorrência será grande.
- Se o valor  $x_i$  for comum, a surpresa  $-\log p(x_i)$  será pequena.
- A surpresa é uma variável aleatória:  $-\log p(X)$ .
- Qual a surpresa ESPERADA se repetirmos o procedimento de selecionar  $X$  com a distribuição acima?

# Entropia de v.a. discreta

- Qual a surpresa ESPERADA que a quantidade aleatória  $-\log p(X)$  acarreta?

Valores Possíveis	$x_1$	$x_2$	...	$x_M$
Probabilidades	$p(x_1)$	$p(x_2)$	...	$p(x_M)$
Surpresas	$-\log p(x_1)$	$-\log p(x_2)$	...	$-\log p(x_M)$

- Esperança é a soma de cada valor possível vezes sua probabilidade de ocorrência

$$\begin{aligned}
 \mathbb{H}_p(p) &= \sum_{i=1}^n -\log(p(x_i)) p(x_i) \\
 &= \mathbb{E}_p \{-\log(p(X))\}
 \end{aligned}$$

- Esta fórmula é a definição de entropia de uma distribuição de probabilidade discreta.

# Entropia de v.a. discreta

- Entropia de v.a. discreta:

$$\mathbb{H}_p(p) = \sum_{i=1}^n -\log(p(x_i)) p(x_i) = \mathbb{E}_p \{-\log(p(X))\}$$

- Estude esta última notação.
- Perceba que  $p(X)$  é o valor de  $p(x_i)$  na tabela escolhido ao acaso como função do valor de  $X$ .
- A variável  $X$ , por sua vez, é selecionada com as mesmas probabilidades  $p$  da tabela.
- O sub-índice  $p$  sob o símbolo da função esperança e em  $\mathbb{H}_p(p)$  é para enfatizar que o  $X$  aleatório no argumento da função possui distribuição dada por  $p$  na tabela acima.
- A notação  $\mathbb{H}_p(p)$  parece redundante mas ela será útil quando definirmos a distância de Kullback-Leibler.

## Exemplo

- $X$  é v.a. discreta com  $M$  valores equiprováveis.
- Isto é,  $\mathbb{P}(X = x_i) = 1/M$  para todo valor  $x_i$ , com  $i = 1, 2, \dots, M$ .
- Então  $\mathbb{H}_p(p)$  é dada por

$$\begin{aligned}
 \mathbb{E}_p \{-\log(p(X))\} &= \sum_{i=1}^M -\log\left(\frac{1}{M}\right) \frac{1}{M} \\
 &= M \frac{1}{M} (-\log M^{-1}) \\
 &= \log(M)
 \end{aligned}$$

- Assim, a entropia  $\mathbb{H}_p(p)$  de uma uniforme é o logaritmo do número de classes equiprováveis.

## Exemplo

- $X$  é v.a. com distribuição Poisson com parâmetro  $\lambda$ .
- Então

$$\begin{aligned}\mathbb{E}_p \{-\log(p(X))\} &= \sum_{i=0}^{\infty} -\log\left(\frac{\lambda^k e^{-\lambda}}{k!}\right) \frac{\lambda^k e^{-\lambda}}{k!} \\ &= \lambda - \sum_{i=0}^{\infty} \log\left(\frac{\lambda^k}{k!}\right) \frac{\lambda^k}{k!} e^{-\lambda}\end{aligned}$$

- A entropia  $\mathbb{H}_p(p)$  da distribuição de Poisson não possui uma expressão mais simples que esta.

## Caso contínuo

- Se  $X$  é uma v.a. contínua com densidade  $f(x)$  então

$$\mathbb{H}_f(f) = \int_{\mathbb{R}} -\log(f(x)) f(x) \, dx = \mathbb{E}_f [-\log f(X)]$$

onde o sub-índice  $f$  na esperança indica que  $X$  é selecionada com densidade  $f$ .

- Podemos pensar num procedimento em três etapas:
  - Tome  $X \sim f$
  - Tome a altura aleatória  $f(X)$  da densidade.
  - Tome a esperança de  $-\log(f(X))$ .

## Exemplo - normal

- Suponha que  $X \sim N(\mu, \sigma^2)$ .
- Neste exemplo, ao invés de integramos uma função, podemos usar o fato de que a variável aleatória padronizada  $Z = (X - \mu)/\sigma$  possui distribuição  $N(0, 1)$ .
- Portanto,  $\mathbb{E}(Z) = 0$  e  $\mathbb{V}(Z) = \mathbb{E}(Z^2) = 1$ .
- Temos

$$\begin{aligned}
 -\log f(x) &= -\log \left[ \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left( -\frac{1}{2\sigma^2}(x - \mu)^2 \right) \right] \\
 &= \frac{1}{2} \log(2\pi\sigma^2) + \frac{1}{2} \left( \frac{x - \mu}{\sigma} \right)^2
 \end{aligned}$$

## Exemplo - normal

- Portanto

$$\begin{aligned}\mathbb{H}_f(f) &= -\mathbb{E}_f [\log f(X)] \\ &= \frac{1}{2} \log(2\pi\sigma^2) + \frac{1}{2} \mathbb{E}_f \left( \frac{X - \mu}{\sigma} \right)^2 \\ &= \frac{1}{2} \log(2\pi\sigma^2) + \frac{1}{2} \\ &= \frac{1}{2} \log(2\pi e\sigma^2)\end{aligned}$$

## Exemplo - normal

- Se  $X \sim N(\mu, \sigma^2)$  então  $\mathbb{H}_f(f) = 0.5 \log(2\pi e \sigma^2)$ .
- Veja que a entropia depende apenas de  $\sigma$  e não de  $\mu$ .
- Além disso, a entropia aumenta com  $\sigma$  numa escala logarítmica.
- Outro fato curioso: com v.a.'s contínuas, a entropia pode ser negativa se  $\sigma^2 < 1/(2\pi e)$ .
- As vezes, vamos escrever simplesmente  $\mathbb{H}(X)$  para significar  $\mathbb{H}_f(f)$


# Teoria da informação

- Minimum Description Length:
- Entropy represents the minimum average number of bits needed to encode the outcomes of the random variable.
- On average, no more efficient code can exist to represent the information in the random variable.

# Medindo distâncias entre distribuições

- Ao comparar duas grandezas físicas  $A$  e  $B$  (tais como duas massas, duas velocidades ou duas cargas elétricas) sabemos dizer se  $A$  e  $B$  são aproximadamente iguais ou muito diferentes.
- E ao comparar as *distribuições* de duas variáveis aleatórias  $X$  e  $Y$ , quando podemos dizer que elas são muito diferentes? Como medir isto?
- Exemplo:  $X \sim N(0, 1)$ ,  $Y \sim N(1, 1)$  e  $Z \sim N(5, 1)$ ,
- Esperamos que a distribuição de  $Y$  seja próxima daquela de  $X$  e afastada da distribuição de  $Z$ .
- Mas e se  $Z \sim N(0.5, 2^2)$ ? Qual seria mais próxima de  $X$ ?  $Y$  ou  $Z$ ?

# Comparando gaussianas



**Figura:** Esquerda:  $N(0, 1)$  e  $N(1, 1)$  em linha sólida e  $N(5, 1)$  em linha tracejada. Direita:  $N(0, 1)$  e  $N(1, 1)$  em linha sólida e  $N(0.5, 2^2)$  em linha tracejada.

# Comparando densidades arbitrárias







Figura: How to compare?

# Comparando densidades multivariadas



# Medidas de distância entre distribuições

- Existem muitas medidas de distância entre duas distribuições de probabilidade:
  - Kolmogorov:  $\sup_x |F_1(x) - F_2(x)|$ , onde  $F_i$  é a função de distribuição acumulada
  - Hellinger:  $H(F_1, f_2) = \sqrt{0.5 \int (\sqrt{f_1(x)} - \sqrt{f_2(x)})^2 dx}$ .
  - Variação total:  $TV(f_1, f_2) = 0.5 \int |f_1(x) - f_2(x)| dx$  Pode-se mostrar que a distância da variação total pode ser escrita como  $\sup_A |\int_A (f_1(x) - f_2(x)) dx| = \sup_A |\mathbb{P}_1(A) - \mathbb{P}_2(A)|$ : a maior diferença possível entre as probabilidades de  $A$  atribuídas por  $f_1$  e  $f_2$ .
  - $\int |f_1(x) - f_2(x)| dx$
  - Existem várias conexões entre as diferentes distâncias. Por exemplo:

$$H^2(f_1, f_2) \leq TV(f_1, f_2) \leq \sqrt{2}H(F_1, f_2)$$

# Medidas de distância entre distribuições

- Qualquer uma dessas medidas é intuitivamente razoável e poderia ser a base de uma teoria de seleção de modelos.
- Entretanto, a distância que gerou mais resultados teóricos e práticos foi a distância de Kullback-Leibler, definida a seguir E DENOTADA POR  $KL$ .

## Suporte e surpresa

- Suponha que temos duas distribuições  $f_1$  e  $f_2$  competindo como modelos para descrever alguns dados.
- Seja  $\mathcal{S}$  o suporte da distribuição  $f_1$ . Isto é,
  - No caso discreto:  $\mathcal{S}_1 = \{z; \mathbb{P}_1(X = z) > 0\}$ ,
  - No caso contínuo,  $\mathcal{S}_1 = \{z; f_1(z) > 0\}$
- Vamos assumir que  $\mathcal{S}_1 = \mathcal{S}_2 = \mathcal{S}$ .
- Para cada  $z \in \mathcal{S}$ , calculamos a surpresa ocasionada por gerar  $z$  sob  $f_1$  e sob  $f_2$ .

# Surpresa

- Para cada  $z \in \mathcal{S}$ , vemos a surpresa  $-\log(f_i(z))$  de ocorrência sob  $f_1$  e sob  $f_2$ .
- Se as duas distribuições são parecidas, esperamos que as surpresas  $-\log(f_1(z))$  e  $-\log(f_2(z))$  sejam similares para todo  $z$ .
- A diferença de surpresa é

$$-\log(f_2(z)) - (-\log(f_1(z))) = \log\left(\frac{f_1(z)}{f_2(z)}\right)$$

- Note que ela é o logaritmo da razão de verossimilhança do modelo 1 versus o modelo 2.
- Se  $\log(f_1(z)/f_2(z)) = 0$ , o valor  $z$  é igualmente provável nas duas distribuições
- Se  $\log(f_1(z)/f_2(z)) > 0$ , o valor  $z$  tem mais chance de ocorrer sob a distribuição 1.

## Tirando a média

- Para ter uma idéia global ou um resumo da diferença de supresas considerando todos os possíveis valores  $z$ , tiramos uma “média” das diferenças  $\log(f_1(z)/f_2(z)) > 0$ .
- Queremos uma média ponderada sobre todos os valores possíveis de  $z \in \mathcal{S}$ .
- Queremos dar mais peso às discrepâncias  $\log(f_X(z)/f_Y(z))$  associadas aos valores  $z$  que têm mais chance de ocorrer.
- Para isto, precisamos escolher um modelo de probabilidade para os valores  $z \in \mathcal{S}$ . Temos dois modelos possíveis:  $f_1(z)$  ou  $f_2(z)$ .
- De maneira um tanto arbitrária, vamos escolher  $f_1(z)$  para descrever as frequências dos valores  $z \in \mathcal{S}$ .

# Kullback e Leibler (1951)

- A medida de Kullback-Leibler é definida no caso contínuo como

$$KL(f_1, f_2) = 2 \int_{\mathcal{S}} \log \left( \frac{f_1(z)}{f_2(z)} \right) f_1(z) dz = \mathbb{E}_{Z \sim f_1} \left( \frac{f_1(Z)}{f_2(Z)} \right)$$

- No caso discreto, como:

$$KL(p_1, p_2) = 2 \sum_{z_i \in \mathcal{S}} \log \left( \frac{\mathbb{P}_1(X = z_i)}{\mathbb{P}_2(X = z_i)} \right) \mathbb{P}_1(X = z_i) = \mathbb{E}_{Z \sim p_1} \left( \frac{p_1(Z)}{p_2(Z)} \right)$$

- Algumas vezes, a definição não utiliza a constante 2.

# KL em passos

- Observe que  $KL$  é equivalente ao seguinte procedimento:
  - $X$  é uma v.a. com densidade  $f_1(x)$ .
  - Ao gerar um valor aleatório  $X$  sob  $f_1$ , calcule a v.a.  $Z = h(X) = 2 \log(f_1(X)/f_2(X))$ .
  - A seguir, tome esperança de  $Z$  (lembrando que  $X$  segue a distribuição  $f_1$ ):

$$\begin{aligned}
 KL(f_1, f_2) &= \mathbb{E}_1[h(X)] \\
 &= 2 \mathbb{E}_1 \left[ \log \left( \frac{f_1(X)}{f_2(X)} \right) \right] \\
 &= 2 \int \log \left( \frac{f_1(x)}{f_2(x)} \right) f_1(x) dx
 \end{aligned}$$

## Exemplo: Poisson

- $X \sim \text{Poisson}(\mu_1)$  e  $Y \sim \text{Poisson}(\mu_2)$ .

- Temos

$$\log \left( \frac{p_X(k)}{p_Y(k)} \right) = \log \left( \frac{\mu_1^k \exp(-\mu_1)/k!}{\mu_2^k \exp(-\mu_2)/k!} \right) = k \log \left( \frac{\mu_1}{\mu_2} \right) - (\mu_1 - \mu_2)$$

- Por exemplo, se  $\mu_1 = 3$  e  $\mu_2 = 5$  então  
 $\log(p_X(k)/p_Y(k)) = k \log(3/5) - (3 - 5) = -0.51 k + 2$ .
- Fazemos  $k$  aleatório com a distribuição de  $X$  e a medida de Kullback-Leibler é

$$\begin{aligned} KL(p_X, p_Y) &= 2 E_X \left[ X \log \left( \frac{\mu_1}{\mu_2} \right) - (\mu_1 - \mu_2) \right] \\ &= 2 \left[ E_X(X) \log \left( \frac{\mu_1}{\mu_2} \right) - (\mu_1 - \mu_2) \right] \\ &= 2 \left[ \mu_1 \log \left( \frac{\mu_1}{\mu_2} \right) - (\mu_1 - \mu_2) \right] \end{aligned}$$

## Exemplo: Poisson

- Vimos que, se  $X \sim \text{Poisson}(\mu_1)$  e  $Y \sim \text{Poisson}(\mu_2)$ , então

$$KL(p_X, p_Y) = 2 \left[ \mu_1 \log \left( \frac{\mu_1}{\mu_2} \right) - (\mu_1 - \mu_2) \right]$$

- Por exemplo, se  $\mu_1 = 3$  e  $\mu_2 = 5$ , teremos  $KL(p_X, p_Y) = 0.9350$ .
- Se  $\mu_1 = 30$  e  $\mu_2 = 50$ , teremos  $KL(p_X, p_Y) = 9.3504$ , o valor anterior multiplicado por 10.
- Se  $\mu_1 = 0.3$  e  $\mu_2 = 0.5$ , teremos  $KL(p_X, p_Y) = 0.093504$ , o primeiro valor dividido por 10.
- De fato, é bem fácil mostrar que, se  $\mu_1$  e  $\mu_2$  são multiplicados por uma mesma constante  $c > 0$ , a distância  $KL$  entre duas Poissons também é multiplicada por  $c$  (basta olhar a fórmula).

# Comparando Poissons




Figura: Different Poissons

## *KL* não é rigorosamente uma distância

- Em geral,  $KL(f_1, f_2) \neq KL(f_2, f_1)$ .
- Isto é,  $KL$  não é simétrica nos seus argumentos.
- Isto implica que a medida de Kullback-Leibler não é, de fato, uma medida de distância no sentido matemático do termo.
- A distância  $KL$  de  $f_1$  até  $f_2$  não é igual à distância  $KL$  de  $f_2$  até  $f_1$

## Poisson e distância $KL$

- Com  $X \sim \text{Poisson}(\mu_1)$  e  $Y \sim \text{Poisson}(\mu_2)$ , temos

$$KL(p_X, p_Y) = 2 \left[ \mu_x \log \left( \frac{\mu_x}{\mu_y} \right) - (\mu_x - \mu_y) \right]$$

- Se  $\mu_x = 3$  e  $\mu_y = 5$ , teremos  $KL(p_X, p_Y) = 0.9350$ .
- Mas se trocarmos, fazendo  $\mu_x = 5$  e  $\mu_y = 3$ , teremos  $KL(p_X, p_Y) = 1.108256$ .
- Vamos tentar entender o porquê dessa diferença daqui a pouco.

## Distância $KL$ é assimétrica

- No caso discreto,  $KL$  é definida assim:

$$KL(p_1, p_2) = \mathbb{E}_{Z \sim p_1} \log \left( \frac{p_1(Z)}{p_2(Z)} \right)$$

- Geramos um dado aleatório  $Z$  por  $p_1$  (aqui está a assimetria)
- Em seguida, olhamos quão mais provável é este  $Z$  sob  $p_1$  relativamente à  $p_2$  calculando  $p_1(Z)/p_2(Z)$
- Por exemplo, se  $Z = z$  e  $f_1(z)/f_2(z) = 3$ , então o  $z$  gerado (por  $p_1$ ) é 3 vezes mais provável sob  $p_1$  do que sob  $p_2$ .
- Se  $p_1 \approx p_2$ , esperamos que essa razão  $p_1(Z)/p_2(Z)$  seja tipicamente próxima de 1 para todo  $Z$ .
- Se  $p_1$  for muito distante de  $p_2$ , esperamos que essa razão  $p_1(Z)/p_2(Z)$  seja em geral bem maior que 1 (dado que  $Z$  veio de  $p_1$ ).

## Distância $KL$ é assimétrica

- O fato é que olhamos a distância  $KL(p_1, P_2)$  numa forma assimétrica.
- Um dado  $Z$  é gerado de  $p_1$ . Então  $KL(p_1, p_2)$  mede o quanto podemos esperar que esse dado aleatório de  $p_1$  pode ter sido gerado por  $p_2$ .
- $KL(p_2, p_1)$  mede a situação reversa: um dado  $Z$  é gerado por  $p_2$  e nos pergutamos se é razoável que ele tenha vindo de  $p_1$ .
- O exemplo a seguir mostra que é razoável que  $KL(p_2, p_1) \neq KL(p_1, p_2)$ .

## Distância $KL$ é assimétrica

- Considere  $f_1(x)$  uma uniforme  $U(0, 1)$  e  $f_2(x)$  uma Beta( $20, 20$ ), bem concentrada em  $(0.3, 0.7)$ .




Figura: Densidades de  $f_1(x) \sim U(0, 1)$  e  $f_2(x) \sim \text{Beta}(20, 20)$ .

## Distância $KL$ é assimétrica

- $f_1(x) \sim U(0, 1)$  e  $f_2(x) \sim \text{Beta}(20, 20)$ , bem concentrada em  $(0.3, 0.7)$ .
- Um dado vindo de  $f_2$  estará em geral bem concentrado em torno de  $1/2$  e pode facilmente ser considerado como sendo gerado por uma  $U(0, 1)$ . Por exemplo, se  $Z = 0.4$  é gerado, poderíamos facilmente tomá-lo como tendo sido gerado por uma  $U(0, 1)$ .
- Veja (a partir do gráfico) que  $2 \log(f_1(z)/f_2(z))$  fica entre  $2 \log(1/1) = 0$  e  $2 \log(5/1) = 3.2$ .
- Podemos facilmente obter por simulação  
 $KL(\text{Beta}(20, 20), U(0, 1)) \approx 2.2$ .

## Distância $KL$ é assimétrica

- Vamos olhar agora a situação reversa: suponha que geramos  $Z \sim U(0, 1)$ .
- Seria razoável esperar que este  $Z$  venha de uma  $\text{Beta}(20, 20)$ ?
- Se  $Z \in (0.3, 0.7)$  n'ao teremos razão para descrtar essa possibilidade.
- Entretanto,  $\mathbb{P}(U(0, 1) \notin (0.3, 0.7)) = 0.6$ .
- Isto é, existe uma chance razoável da  $U(0, 1)$  gerar um dado fora de  $(0.3, 0.7)$  onde a  $\text{Beta}(20, 20)$  está concentrada.
- Um dado fora de  $(0.3, 0.7)$  dificilmente seria gerado por uma  $\text{Beta}(20, 20)$ .
- De fato, temos  $KL(U(0, 1), \text{Beta}(20, 20)) \approx 20$  (por simulação)
- Isto é,  
 $20 \approx KL(U(0, 1), \text{Beta}(20, 20)) >> KL(\text{Beta}(20, 20), U(0, 1)) \approx 2$

## Caso normal

- Sejam  $\mathbf{X} \sim N_n(\boldsymbol{\mu}_1, \sigma_1^2 I_n)$  e  $\mathbf{Y} \sim N_n(\boldsymbol{\mu}_2, \sigma_2^2 I_n)$ .
- Neste caso,

$$\begin{aligned} \log \left( \frac{f_{\mathbf{X}}(\mathbf{z})}{f_{\mathbf{Y}}(\mathbf{z})} \right) &= \log \left( \frac{(2\pi\sigma_1^2)^{-n/2} \exp(-\|\mathbf{z} - \boldsymbol{\mu}_1\|^2/(2\sigma_1^2))}{(2\pi\sigma_2^2)^{-n/2} \exp(-\|\mathbf{z} - \boldsymbol{\mu}_2\|^2/(2\sigma_2^2))} \right) \\ &= n \log \left( \frac{\sigma_2}{\sigma_1} \right) - \frac{1}{2\sigma_1^2} \|\mathbf{z} - \boldsymbol{\mu}_1\|^2 + \frac{1}{2\sigma_2^2} \|\mathbf{z} - \boldsymbol{\mu}_2\|^2 \end{aligned}$$

- Usando que  $\|\mathbf{X} - \boldsymbol{\mu}_1\|^2/\sigma_1^2 \sim \chi^2(n)$  (qui-quadrado com  $n$  graus de liberdade) e que  $\|\mathbf{X} - \boldsymbol{\mu}_2\|^2$  é uma qui-quadrado não-central podemos deduzir:

$$KL(f_{\mathbf{X}}, f_{\mathbf{Y}}) = 2 \left[ n \log \left( \frac{\sigma_2}{\sigma_1} \right) - \frac{n}{2} + \frac{n\sigma_1^2}{2\sigma_2^2} + \frac{\|\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2\|^2}{2\sigma_2^2} \right],$$

- É uma função da distância euclidiana entre os vetores de médias e das razões entre as variâncias das distribuições.

## Caso normal

- Se  $X \sim N(0, 1)$ ,  $Y \sim N(1, 1)$  e  $Z \sim N(5, 1)$ , então
- $KL(f_X, f_Y) = 1$ ,  $KL(f_X, f_Z) = 25$  e  $KL(f_Y, f_Z) = 16$
- Mas se agora tivermos  $Z \sim N(0.5, 2^2)$ , então
- $KL(f_X, f_Y) = 1$  (como antes) e  $KL(f_X, f_Z) = 0.6988$  e  $KL(f_Y, f_Z) = 0.6987$ .
- Ou seja,  $Z$  está igualmente distante de  $X$  e  $Y$  e mais perto de cada uma delas que a distância entre  $X$  e  $Y$ .

## Assimetria - Caso normal

- Seja  $Y_1 \sim N(0, \sigma_1^2)$ ,  $Y_2 \sim N(0, \sigma_2^2)$

- 

$$KL(f_1, f_2) = 2 \log \left( \frac{\sigma_2}{\sigma_1} \right) - 1 + \frac{\sigma_1^2}{\sigma_2^2}$$

- Considere  $\sigma_1 = 1$  e  $\sigma_2 = 5$
- Temos  $KL(N(0, 1), N(0, 5^2)) = 2.26$
- mas  $KL(N(0, 5^2), N(0, 1)) = 20.78$
- Todo dado vindo de uma  $N(0, 1)$  pode se passar como sendo gerado de uma  $N(0, 5^2)$
- Mas quase todo dado vindo de uma  $N(0, 5^2)$  não consegue se passar como

# KL divergência entre normais multivariadas gerais

- Sejam  $\mathbf{X} \sim N_n(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$  e  $\mathbf{Y} \sim N_n(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$ .
- A divergência de Kullback-Leibler entre  $f_{\mathbf{X}}$  e  $f_{\mathbf{Y}}$  é dada por:

$$KL(f_{\mathbf{X}}, f_{\mathbf{Y}}) = \frac{1}{2} \left[ \log \left( \frac{|\boldsymbol{\Sigma}_2|}{|\boldsymbol{\Sigma}_1|} \right) - n + \text{tr}(\boldsymbol{\Sigma}_2^{-1} \boldsymbol{\Sigma}_1) + \right. \\ \left. + (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)^\top \boldsymbol{\Sigma}_2^{-1} (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1) \right].$$

- It is not symmetric

## Jensen-Shannon

- Algumas vezes usamos uma outra medida (simétrica) chamada Jensen-Shannon divergence:

$$JS(f_1, f_2) = \frac{1}{2} (KL(f_1, f_m) + KL(f_2, f_m))$$

onde

$$f_m(x) = (f_1(x) + f_2(x))/2 .$$

é a mistura de  $f_1$  e  $f_2$ .

- Continuaremos a usar  $KL(f_1, f_2)$ , chamando-a de distância entre as distribuições  $f_1$  e  $f_2$ .

# Local KL Divergence: A Quadratic Approximation

- Let  $p(y; \theta)$  be a smooth parametric family of densities.
- We analyze the local behavior of the Kullback-Leibler divergence:

$$KL(p(y; \theta) \parallel p(y; \theta + \delta))$$

when  $\delta$  is small.

- This KL measures the discrepancy between  $p(y; \theta)$  and its perturbed version  $p(y; \theta + \delta)$ .
- We will show that:

$$KL(p(y; \theta) \parallel p(y; \theta + \delta)) \approx \frac{1}{2} \delta^\top \mathcal{I}(\theta) \delta$$

where  $\mathcal{I}(\theta)$  is the Fisher Information Matrix.

# Taylor Expansion of the Log-Likelihood

- The KL divergence can be rewritten as:

$$KL(p(y; \theta) \| p(y; \theta + \delta)) = \mathbb{E}_{\theta} \left[ \log \frac{p(Y; \theta)}{p(Y; \theta + \delta)} \right]$$

- Since  $\log p(Y; \theta + \delta)$  is smooth, apply a second-order Taylor expansion:

$$\log p(Y; \theta + \delta) \approx \log p(Y; \theta) + \delta^\top \nabla_{\theta} \log p(Y; \theta) + \frac{1}{2} \delta^\top \nabla_{\theta}^2 \log p(Y; \theta) \delta$$

- Substituting into the KL formula:

$$KL \approx \mathbb{E}_{\theta} \left[ -\delta^\top \nabla_{\theta} \log p(Y; \theta) - \frac{1}{2} \delta^\top \nabla_{\theta}^2 \log p(Y; \theta) \delta \right]$$

## Expectations of the Expansion Terms

- The first-order term is the score and it has zero expectation:

$$\mathbb{E}_{\theta} [\nabla_{\theta} \log p(Y; \theta)] = 0$$

- The expectation of the second-order term gives the Fisher Information:

$$\mathbb{E}_{\theta} [-\nabla_{\theta}^2 \log p(Y; \theta)] = \mathcal{I}(\theta)$$

- Therefore:

$$KL(p(y; \theta \| \theta + \delta)) \approx \frac{1}{2} \delta^T \mathcal{I}(\theta) \delta$$

- This is a second-order local approximation to the KL divergence.

# Interpretation of the Approximation

- Note that the KL does NOT make use of the parametrization while the Fisher information does.
- The matrix  $I(\theta)$  serves as a local metric on the parameter space.
- Small perturbations  $\delta$  around  $\theta$  result in quadratic increases in KL divergence.
- If  $I(\theta)$  is large, then small changes in  $\theta$  greatly affect the distribution.
- This result is central to:
  - Information geometry
  - Asymptotic theory in statistics
  - Bayesian inference (e.g., Laplace approximations)

# KL Divergence Between Two Exponentials

- Let  $f_1(y) = \lambda_1 e^{-\lambda_1 y}$  and  $f_2(y) = \lambda_2 e^{-\lambda_2 y}$  be two exponential densities on  $y > 0$ .
- The Kullback-Leibler divergence from  $f_1$  to  $f_2$  is defined as:

$$KL(f_1 \| f_2) = \int_0^{\infty} f_1(y) \log \left( \frac{f_1(y)}{f_2(y)} \right) dy$$

- Plugging in the density functions:

$$KL(f_1 \| f_2) = \int_0^{\infty} \lambda_1 e^{-\lambda_1 y} \left[ \log \left( \frac{\lambda_1}{\lambda_2} \right) + (\lambda_2 - \lambda_1)y \right] dy$$

# KL Divergence Between Two Exponentials (cont.)

- Splitting the integral:

$$KL(f_1\|f_2) = \log\left(\frac{\lambda_1}{\lambda_2}\right) \underbrace{\int_0^{\infty} \lambda_1 e^{-\lambda_1 y} dy}_{=1} + (\lambda_2 - \lambda_1) \underbrace{\int_0^{\infty} y \lambda_1 e^{-\lambda_1 y} dy}_{=\frac{1}{\lambda_1}}$$

- Final result:

$$KL(f_1\|f_2) = \log\left(\frac{\lambda_1}{\lambda_2}\right) + \frac{\lambda_2}{\lambda_1} - 1$$

- This expression is always non-negative and equals 0 if and only if  $\lambda_1 = \lambda_2$ .

# KL Divergence and information

- Let  $f_1 = f_\lambda$  and  $f_2 = f_{\lambda+\delta}$ .

$$KL(f_\lambda \| f_{\lambda+\delta}) = \log \left( \frac{\lambda}{\lambda + \delta} \right) + \frac{\lambda + \delta}{\lambda} - 1$$

- We found that

$$KL(f_\lambda \| f_{\lambda+\delta}) \approx \frac{1}{2} \cdot \delta^2 \cdot \mathcal{I}(\lambda) = \frac{1}{2} \cdot \delta^2 \cdot \frac{1}{\lambda^2}$$

- Are they similar? Take  $\lambda = 3$  and  $\delta \in [-2, 2]$ . We will plot  $KL(f_\lambda \| f_{\lambda+\delta})$  and the approximation versus  $\delta$ .

# KL Divergence and information




Figura:  $KL(f_\lambda \| f_{\lambda+\delta}) \approx \frac{1}{2} \cdot \delta^2 \cdot \mathcal{I}(\lambda)$ . Black: KL. Blue: Approximation with Information matrix

## Relembrando de probab

- Se  $Y_1, Y_2, \dots, Y_n$  são i.i.d. com a mesma distribuição que  $Y$  e se  $\mu = E(Y)$  então

$$\hat{\mu} = \sum_i Y_i / n \rightarrow \mu$$

- Isto é, o estimador  $\sum_i Y_i / n$  (média aritmética dos elementos da amostra i.i.d.) converge para a média populacional (a esperança) de  $Y$ .
- Isto vale PARA QUALQUER V.A. QUE POSSUA esperança.
- Repetindo: QUALQUER v.a.  $Y$ .
- Isto é muito simples mas muito importante quando acoplado com a idéia de transformar uma v.a. como veremos no próximo slide.

## Relembrando de probab

- Se  $X$  é uma v.a. e  $Y = h(X)$  é uma v.a. obtida como função de  $X$ .
- Por exemplo,  $Y = X^2$  ou então  $Y = \log(1 + X^2)$
- Se  $X_1, \dots, X_n$  são i.i.d. com distribuição de  $X$  então  $Y_1 = h(X_1), \dots, Y_n = h(X_n)$  são i.i.d. com uma distribuição de  $Y = h(X)$ .
- Por exemplo:  $Y_1 = X_1^2, Y_2 = X_2^2, \dots, Y_n = X_n^2$  são v.a.'s i.i.d.
- Outro exemplo:  
 $Y_1 = \log(1 + X_1^2), Y_2 = \log(1 + X_2^2), \dots, Y_n = \log(1 + X_n^2)$  são v.a.'s i.i.d.

## Relembrando de probab

- Então  $\mu_Y = E(Y) = E(h(X))$  pode ser estimado consistentemente pela média aritmática  $\hat{\mu}_Y = \sum_i Y_i/n = \sum_i h(X_i)/n$ .
- Por exemplo:

$$\frac{Y_1 + Y_2 + \dots + Y_n}{n} = \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n} \rightarrow \mathbb{E}(X^2) = \mathbb{E}(Y)$$

ou

$$\frac{Y_1 + \dots + Y_n}{n} = \frac{\log(1 + X_1^2) + \dots + \log(1 + X_n^2)}{n} \rightarrow \mathbb{E}(\log(1 + X^2))$$

## Estimando Kullback-Leibler

- A distância  $KL$  é apenas uma esperança de uma v.a.  $Y = h(X)$  onde  $X$  é selecionada com a distribuição  $f_1$ :

$$KL(f_1, f_2) = 2\mathbb{E}_1 [h(X)] = 2\mathbb{E}_1 \left[ \log \left( \frac{f_1(X)}{f_2(X)} \right) \right]$$

onde  $h(x)$  é a função dada por

$$h(x) = \log \left( \frac{f_1(x)}{f_2(x)} \right)$$

- Se tivermos uma amostra i.i.d. de  $X$  obtida da distribuição  $f_1$ , podemos transformar cada  $X$  com a função  $h$  e a seguir calcular a sua média aritmética.
- Este valor será aproximadamente igual a esperança teórica.

# Estimando Kullback-Leibler

- Se  $X_1, \dots, X_n$  são i.i.d. com distribuição com densidade  $f_1$ , podemos estimar

$$KL(f_1, f_2) = 2\mathbb{E}_1 \left[ \log \left( \frac{f_1(X)}{f_2(X)} \right) \right]$$

pela média aritmética dos valores  $h(X_i)$ :

$$\widehat{KL(f_1, f_2)} = 2 \frac{1}{n} \sum_i \log \left( \frac{f_1(X_i)}{f_2(X_i)} \right)$$

- Não podemos usar os dados vindos de  $f_1$  para estimar desse modo simples a distância  $KL(f_2, f_1)$  pois precisamos de dados vindos de  $f_2$  nesse caso.

## Exemplo

- $X$  e  $Y$  são v.a.'s Poisson com médias 3 e 5. Então

$$\log \left( \frac{p_X(k)}{p_Y(k)} \right) = k \log \left( \frac{3}{5} \right) - (3 - 5) = 2 - 0.511 k$$

- Temos  $KL(p_X, p_Y) = 2(2 - 0.511 E_X(X)) = 2(0.468)$ .
- Neste caso, sabemos exatamente qual é o valor de  $KL(p_X, p_Y)$  e portanto, nem faz sentido estimá-lo. No entanto, se mesmo assim quiséssemos, podemos fazer o seguinte:
- Os valores observados de uma amostra de tamanho 10 de  $X$  com distribuição Poisson de média 3 são os seguintes:

5, 3, 4, 1, 2, 5, 2, 1, 8, 2

- Então  $KL(p_X, p_Y) = 2(0.468)$  pode ser estimado por

$$\widehat{KL(p_X, p_Y)} = \frac{2}{10} \sum_i (k_i \log(3/5) + 2) = 2(0.314)$$

# Todo modelo é correto

- Em análise de dados com modelos paramétricos, selecionamos uma classe de distribuições  $f(\mathbf{y}, \boldsymbol{\theta})$  para o vetor aleatório  $\mathbf{Y}$ .
- Fizemos uma análise de como o MLE  $\hat{\boldsymbol{\theta}}$  se comporta quando um dos elementos desta classe é o modelo gerador dos dados.
- Suponha que  $\boldsymbol{\theta}_0 \in \Theta$  é o verdadeiro valor do parâmetro.
- Isto é, os dados são gerados pela distribuição  $f(\mathbf{y}, \boldsymbol{\theta}_0)$
- Então, o MLE  $\hat{\boldsymbol{\theta}}$  baseado numa amostra possui as seguintes propriedades:
  - $\hat{\boldsymbol{\theta}} \rightarrow \boldsymbol{\theta}_0$  quando  $n \rightarrow \infty$  (é consistente)
  - $\mathbb{E}(\hat{\boldsymbol{\theta}}) \approx \boldsymbol{\theta}_0$  (é aproximadamente não-viciado)
  - $\mathbb{V}(\hat{\boldsymbol{\theta}}) \approx \mathbb{I}^{-1}(\boldsymbol{\theta}_0)$
  - $\hat{\boldsymbol{\theta}} \approx N(\boldsymbol{\theta}_0, \mathbb{I}^{-1}(\boldsymbol{\theta}_0))$

# Todo modelo é falso


- Uma frase famosa de George Box é: *Todo modelo é falso mas alguns são úteis.*
- Praticamente sempre, nossos modelos são distribuições idealizadas e simplificadoras. Esperamos que eles sejam capazes de descrever de forma aproximada o mecanismo verdadeiro que gera os dados.
- Mas se o modelo verdadeiro que gera os dados não é um membro  $f(\mathbf{y}, \theta_0)$  da classe  $f(\mathbf{y}, \theta)$ , então não existe nenhum  $\theta_0$  verdadeiro.
- Neste caso, o *MLE* estará estimando o quê?
- Ele converge para algum lugar quando a amostra aumenta?
- Se existir um ponto de convergência, ele faz algum sentido prático?
- A discussão a seguir vai supor que os dados sejam i.i.d. mas ela é válida num contexto mais geral de dados independentes mas não i.d. ou até mesmo de dados dependentes.

# Minimizando $KL$

- Suponha que  $g(y)$  é a verdadeira densidade que gera os dados observados.
- Propomos um modelo parametrizado como aproximação para  $g$ .
- O modelo é uma classe (um conjunto) de densidades  $f(y, \theta)$  indexado pelo parâmetro  $\theta$ .
- Vamos denotar por  $f_{\theta}$  a densidade  $f(y, \theta)$ .
- Uma estratégia interessante para modelar os dados gerados por  $g$  é procurar na classe de densidades  $\{f(y, \theta)\}$  aquela que minimiza a distância  $KL$ .
- Isto é, vamos procurar na classe  $\{f(y, \theta)\}$  aquele valor  $\theta_0$  tal que a densidade  $f(y, \theta_0)$  seja a mais próxima possível de  $g$ .
- Em símbolos,

$$\theta_0 = \arg_{\theta} \min KL(g, f_{\theta})$$

# Minimizando $KL$



**Figura:** Cada ponto em  $\mathbb{R}^3$  representa uma das infinitas distribuições de probabilidade existentes. A distribuição que gera os dados é representada pelo ponto  $g$ . A classe de distribuições do modelo  $\{p(y, \theta)\}$  são os pontos na superfície curva, um conjunto de pontos bem restrito em  $\mathbb{R}^3$ .  $\theta_0$  é a distribuição mais próxima de  $g$  em termos da distância  $KL$ . Também temos o MLE  $\hat{\theta}$  como um ponto aleatório na superfície do modelo.

## Minimizando $KL$

- Se  $\theta_0 = \arg_{\theta} \min KL(g, f_{\theta})$  então  $f(y, \theta_0)$  é o elemento da classe mais próximo de  $g$ .
- Se não pudermos encontrar  $g$ , o melhor que podemos fazer é usar  $f(y, \theta_0)$  em seu lugar.
- Temos

$$KL(g, f_{\theta}) = \mathbb{E}_g \log \left( \frac{g(Y)}{f(Y, \theta)} \right) = \mathbb{E}_g \log (g(Y)) - \mathbb{E}_g \log (f(Y; \theta))$$

- O primeiro termo,  $\mathbb{E}_g(\log g(Y))$ , não depende de  $\theta$ .

# Minimizando $KL$

- Repetindo:

$$KL(g, f_{\theta}) = \mathbb{E}_g \log \left( \frac{g(Y)}{f(Y, \theta)} \right) = \mathbb{E}_g \log (g(Y)) - \mathbb{E}_g \log (f(Y; \theta))$$

- Portanto, minimizar  $KL(g, f_{\theta})$  é o mesmo que procurar o valor de  $\theta$  que minimiza o segundo termo:

$$\theta_0 = \arg_{\theta} \min KL(g, f_{\theta}) = \arg \min \{-\mathbb{E}_g \log (f(Y; \theta))\}$$

- Esse segundo termo é a entropia cruzada de  $f(Y; \theta)$  em relação a  $g$ .
- De forma equivalente, podemos maximizar o negativo desse segundo termos:

$$\theta_0 = \arg \max \mathbb{E}_g \log (f(Y; \theta))$$

# Minimizando $KL$

- Como encontrar este elemento

$$\theta_0 = \arg_{\theta} \min KL(g, f_{\theta}) = \arg \max \mathbb{E}_g \log (f(Y; \theta)) \quad ?$$

- Em alguns casos simples isto é possível, como veremos a seguir.
- $g$  é uma densidade contínua arbitrária e que vai gerar os nossos dados.
- Nosso modelo é a classe de todas as gaussianas:  $\{N(\mu, \sigma^2)\}$ .
- Aqui  $\theta = (\mu, \sigma^2)$ .
- Como encontrar (se é que existe) uma (única??) gaussiana  $N(\mu_0, \sigma_0^2)$  que melhor aproxima uma densidade  $g$  arbitrária minimizando a distância  $KL$ ?
- Isto é, qual é a  $N(\mu, \sigma^2)$  que tem  $KL(g, N(\mu, \sigma^2))$  mínima?

# Minimizando $KL$ na classe das gaussianas

- Queremos  $(\mu_0, \sigma_0^2)$  que minimizem

$$KL(g, N(\mu, \sigma^2)) = 2\mathbb{E}_g \log(g(X)) - 2\mathbb{E}_g \log(\phi(X; \mu, \sigma^2))$$

onde  $\phi(x; \mu, \sigma^2)$  é a densidade de uma gaussiana com parâmetros  $(\mu, \sigma^2)$

- O primeiro termo não depende de  $(\mu, \sigma^2)$  e pode ser ignorado.
- Assim, basta maximizar

$$\begin{aligned} 2\mathbb{E}_g \log(\phi(X; \mu, \sigma^2)) &= 2\mathbb{E}_g \log \left( (2\pi)^{-1/2} - \frac{1}{2} \log \sigma^2 - \frac{1}{2} \left( \frac{X - \mu}{\sigma} \right)^2 \right) \\ &= \text{cte.} - \log \sigma^2 - \mathbb{E}_g \left( \frac{X - \mu}{\sigma} \right)^2 \\ &= \text{cte.} - \log \sigma^2 - \frac{1}{\sigma^2} \mathbb{E}_g (X - \mu)^2 \end{aligned}$$

# Minimizando $KL$ na classe das gaussianas

- Queremos  $(\mu_0, \sigma_0^2)$  que maximizem

$$2\mathbb{E}_g \log (\phi(x; \mu, \sigma^2)) = \text{cte.} - \log \sigma^2 - \frac{1}{\sigma^2} \mathbb{E}_g (X - \mu)^2$$

- Para qualquer valor de  $\sigma^2$  fixo, devemos minimizar  $\mathbb{E}_g (X - \mu)^2$
- $\mathbb{E}_g (X - \mu)^2$  é minimizado se tomarmos  $\mu_0 = \mathbb{E}_g(X)$ .
- Com este valor  $\mu_0$  inserido na expressão acima, temos que achar  $\sigma^2$  que maximize

$$\text{cte.} - \log \sigma^2 - \frac{1}{\sigma^2} \mathbb{E}_g (X - \mu_0)^2$$

- Derivando em  $\sigma^2$  igualando a zero encontramos

$$\sigma_0^2 = \mathbb{E}_g (X - \mu_0)^2 = \mathbb{V}_g(X)$$

# Minimizando $KL$ na classe das gaussianas

- Isto é, dada uma  $g$  qualquer, a gaussiana  $N(\mu, \sigma^2)$  que tem a distância de Kullback-Leibler mínima é  $N(\mu_0, \sigma_0^2)$  onde  $\mu_0 = \mathbb{E}_g(X)$  e  $\sigma_0^2 = \mathbb{V}_g(X)$ .
- Por exemplo, se  $g$  é a densidade de uma exponencial dupla (ou distribuição de Laplace, veja na wikipedia), com esperança 0 e variância 1 então a gaussiana que melhor aproxima é a  $N(0, 1)$ .




Figura: Laplace (linha contínua) e gaussiana mais próxima

## Minimizando $KL$ na classe das gaussianas

- Outro exemplo:  $g$  é a densidade de uma gama com  $\alpha = 4$  e  $\beta = 1$ .  
Isto implica que  $g$  tem esperança 4 e variância 4.
- A gaussiana que melhor aproxima esta gama é a  $N(4, 4)$ .




Figura: Gamma(4, 1) (linha contínua) e gaussiana mais próxima  $N(4, 4)$

# Quando temos o modelo errado, o MLE estima o quê?

- Suponha que o vetor  $\mathbf{Y} = (Y_1, \dots, Y_n)$  é composto de v.a.'s i.i.d. com uma distribuição desconhecida com densidade  $g(\mathbf{y})$ .
- Adotamos um modelo  $f(\mathbf{y}, \theta) = \prod_i f(y_i, \theta)$  para os dados i.i.d. e obtemos o MLE maximizando a log-verossimilhança (dividida pela constante  $n$ ):

$$\hat{\theta} = \arg \max \frac{1}{n} \sum_i \log f(Y_i; \theta)$$

# O MLE estima o quê?

- Para cada valor  $\theta$  fixo, considere as v.a.'s  $W_1 = \log f(Y_1; \theta), \dots, W_n = \log f(Y_n; \theta)$
- A média populacional (a esperança) de  $W$  é

$$\mathbb{E}_g(W) = \mathbb{E}_g(\log f(Y; \theta))$$

onde  $Y$  no lado direito é uma v.a. com densidade  $g(y)$ .

- Lembre-se de um resultado de probab (a lei dos grandes números): A média aritmética de v.a.'s i.i.d. converge para sua esperança populacional.
- A média aritmética baseada na amostra é

$$\frac{W_1 + \dots + W_n}{n} = \frac{1}{n} \sum_i \log f(Y_i; \theta)$$

# O MLE estima o quê?

- Pela Lei dos Grandes números, temos

$$\frac{W_1 + \dots + W_n}{n} \rightarrow \mathbb{E}_g(W)$$

- Ou seja,

$$\frac{1}{n} \sum_i \log f(Y_i; \theta) \rightarrow \mathbb{E}_g(\log f(Y; \theta))$$

para todo  $\theta$  fixo.

- Por definição o MLE de  $\theta$  é o argumento em  $\theta$  que maximiza a log-verossimilhança.
- Em símbolos:

$$\hat{\theta} = \arg_{\theta} \max \frac{1}{n} \sum_i \log f(Y_i; \theta)$$

# O MLE estima o quê?

- Vamos definir  $\theta_0$  como o argumento em  $\theta$  que maximiza

$$\theta_0 = \arg_{\theta} \max \mathbb{E}_g (\log f(Y; \theta))$$

- Mas nós acabamos de ver que maximizar  $\mathbb{E}_g (\log f(Y; \theta))$  em  $\theta$  é o mesmo que minimizar  $KL(g, f_{\theta})$  em  $\theta$ .
- Assim,  $\theta_0$  definido acima tem o mesmo significado que antes:

$$\theta_0 = \arg_{\theta} \max \mathbb{E}_g (\log f(Y; \theta)) = \arg_{\theta} \min KL(g, f(y; \theta))$$

- Vamos agora relacionar o MLE  $\hat{\theta}$  e  $\theta_0$ .

# O MLE estima o quê?

- O MLE  $\hat{\theta}$  é uma v.a. e  $\theta_0$  é um valor fixo no espaço paramétrico, uma constante.
- Em geral,  $\hat{\theta} \neq \theta_0$ .
- Mas eles estão relacionados. Como:

$$\frac{1}{n} \sum_i \log f(Y_i; \theta) \rightarrow \mathbb{E}_g (\log f(Y; \theta))$$

podemos esperar que

$$\hat{\theta} = \arg_{\theta} \max \frac{1}{n} \sum_i \log f(Y_i; \theta) \rightarrow \arg_{\theta} \max \mathbb{E}_g (\log f(Y; \theta)) = \theta_0$$

- De fato, podemos demonstrar isto rigorosamente sob certas condições mas não faremos isto neste curso.

# O MLE estima o quê?

- Assim, temos

$$\hat{\theta} = \arg_{\theta} \max \frac{1}{n} \sum_i \log f(Y_i; \theta) \rightarrow \arg_{\theta} \max \mathbb{E}_g (\log f(Y; \theta)) = \theta_0$$

- A medida que  $n$  cresce, o MLE  $\hat{\theta}$  converge para o valor  $\theta_0$  que minimiza a distância  $KL$  entre o modelo verdadeiro  $g$  e a classe  $\{f(y, \theta)\}$ .
- Agora entedemos o que o MLE está fazendo.
- Existe um elemento  $\theta_0$  da classe de distribuições  $\{f(y, \theta)\}$  que forma nosso modelo que é a mais  $KL$ -próxima possível da distribuição verdadeira  $g$ .
- O MLE  $\hat{\theta}$  é um estimador deste valor  $\theta_0$ .

# O MLE estima o quê?

- Se  $g$  for de fato um elemento  $f(y, \theta_0)$  da classe especificada no modelo, temos todos os resultados que já vimos neste curso:

$$\hat{\theta} \approx N(\theta_0, I^{-1}(\theta_0))$$

- No caso mais comum em que  $g$  não pertence à classe  $\{f(y, \theta)\}$  do modelo, Peter Huber (1967) demonstrou que, se a amostra não é muito pequena:

$$\hat{\theta} \approx N(\theta_0, V)$$

onde  $V$  mistura a informação de Fisher com outra matriz.

# O MLE estima o quê?

- More specifically:

$$\hat{\boldsymbol{\theta}} \approx N(\boldsymbol{\theta}_0, V)$$

onde  $V$  é chamada de variancia sanduiche e é igual a

$$V = H^{-1} J H^{-1}$$

com

$$H = \mathbb{E}_g \left[ \nabla_{\boldsymbol{\theta}}^2 \log f(Y; \boldsymbol{\theta}) \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_0} \right] \quad (\text{Hessiana esperada})$$

$$J = \mathbb{E}_g \left[ \nabla_{\boldsymbol{\theta}} \log f(Y; \boldsymbol{\theta}) \nabla_{\boldsymbol{\theta}} \log f(Y; \boldsymbol{\theta})^\top \Big|_{\boldsymbol{\theta}=\boldsymbol{\theta}_0} \right] \quad (\text{score "quadrado"})$$

- Quando o modelo é correto, teremos  $H = J = \mathcal{I}(\boldsymbol{\theta})$  e  $V$  será a informação de Fisher usual:  $V = \mathcal{I}(\boldsymbol{\theta})$ .

## Estimando $H$ e $J$ a partir dos dados

- Embora as esperanças definindo  $H$  e  $J$  sejam em relação à distribuição verdadeira  $g$ , podemos estimá-las usando a distribuição empírica dos dados e o modelo adotado  $f(y; \theta)$ .
- As derivadas são tomadas em relação a  $\theta$ , mas avaliadas no ponto  $\theta_0$  (desconhecido), que estimamos por  $\hat{\theta}$ .
- Estimativas:

$$\hat{J} = \frac{1}{n} \sum_{i=1}^n \nabla_{\theta} \log f(Y_i; \hat{\theta}) \cdot \nabla_{\theta} \log f(Y_i; \hat{\theta})^{\top}$$

$$\hat{H} = \frac{1}{n} \sum_{i=1}^n \nabla_{\theta}^2 \log f(Y_i; \hat{\theta})$$

- Ambas são obtidas numericamente a partir da função de log-verossimilhança.

# O estimador sanduíche da variância

- Com as estimativas anteriores, construímos a matriz de variância robusta (ou "sanduíche"):

$$\widehat{V} = \widehat{H}^{-1} \widehat{J} \widehat{H}^{-1}$$

- Essa matriz estima a variância assintótica do MLE mesmo quando o modelo está incorretamente especificado.
- É muito usada em:
  - Modelos de verossimilhança mal especificados
  - Equações de estimação generalizadas (GEEs)
  - Econometria (ex: correção de heterocedasticidade de White)
- O mais incrível neste processo é que podemos obter o MLE e uma estimativa  $f(y, \widehat{\theta})$  da melhor aproximação  $f(y, \theta_0)$  de  $g$  sem ter a menor idéia de quem é  $g$ .
- É uma ferramenta poderosa: permite inferência confiável mesmo quando não conhecemos a distribuição verdadeira  $g$ .

# Comparando modelos

- Suponha que temos dois modelos alternativos, 1 e 2.
- Cada um deles é uma classe de distribuições indexadas por parâmetros.
- Digamos,  $\theta$  para o modelo 1 e  $\phi$  para o modelo 2.
- Modelo 1:  $f(y, \theta)$ .
- Modelo 2:  $h(y; \phi)$  (vamos usar  $h$  para as densidades do modelo 2)
- Os parâmetros  $\theta$  e  $\phi$  podem ter dimensões e interpretações físicas diferentes.
- Qual deles é o melhor para descrever dados gerados de uma distribuição  $g$  desconhecida?

## Comparando modelos

- Temos uma medida de distância entre  $g$  e uma classe de distribuições.
- Seja  $\theta_0$  o valor de  $\theta$  que minimiza a distância  $KL(g, f(y, \theta))$ .
- Isto é,

$$\theta_0 = \arg \min KL(g, f(y, \theta))$$

- A distância mínima entre  $g$  e o modelo 1 é  $KL(g, f(y, \theta_0))$ .
- Do mesmo modo, teremos a distância mínima entre  $g$  e o modelo 2 dada por  $KL(g, h(y, \phi_0))$  onde

$$\phi_0 = \arg \min KL(g, h(y, \phi))$$

# Comparando modelos

- Assim, o natural é comparar  $KL(g, f(y, \theta_0))$  e  $KL(g, h(y, \phi_0))$ .
- O que tiver distância mínima é o escolhido.
- Podemos acrescentar um critério adicional: Se o modelo 2 for muito mais complicado que o modelo 1 e se  $KL(g, f(y, \theta_0)) > KL(g, h(y, \phi_0))$  mas a diferença for muito pequena, podemos ficar com o modelo 1, mais simples e que tem praticamente a mesma distância que o modelo 2.
- OK, mas como definir se a distância é pequena?
- E muito mais importante: como calcular  $KL(g, f(y, \theta_0))$  e  $KL(g, h(y, \phi_0))$  na prática?

# Akaike

- Akaike resolveu estes dois problemas para nós.
- A segunda pergunta é fácil: como calcular  $KL(g, f(y, \theta_0))$  e  $KL(g, h(y, \phi_0))$  na prática?
- Como o MLE  $\hat{\theta} \rightarrow \theta_0$  e o MLE  $\hat{\phi} \rightarrow \phi_0$ , o natural é substituir  $\theta_0$  e  $\phi_0$  pelos seus MLEs e comparar  $KL(g, f(y, \hat{\theta}))$  e  $KL(g, h(y, \hat{\phi}))$ .
- Como vimos antes, essas estimativas são simplesmente as log-verossimilhanças de cada modelo no seu valor máximo.
- Isto é, nesta abordagem, bastaria comparar as verosmilhanças maximizadas de cada modelo.
- Entretanto, Akaike mostrou que  $KL(g, f(y, \hat{\theta}))$  não é uma boa estimativa de  $KL(g, f(y, \theta_0))$ .

## Akaike

- Sabemos que  $KL(g, f(y, \hat{\theta})) > KL(g, f(y, \hat{\theta}))$  pois  $\theta_0$  é o minimizador do KL.
- Existe um vício positivo:  $\hat{\theta}$  é aleatório e mostra-se que o valor esperado de  $KL(g, f(y, \hat{\theta}))$  é maior que  $KL(g, f(y, \hat{\theta}))$ :

$$\mathbb{E}_g \left[ KL(g, f(y, \hat{\theta})) \right] > KL(g, f(y, \hat{\theta}))$$

- Este vício é causado por over-fitting: estamos usando os dados de treino para estimar o modelo e também para avaliarmos qual modelo é melhor.
- Akaike encontrou uma fórmula para este vício de over-fitting e com isso corrigiu  $KL(g, f(y, \hat{\theta}))$  e  $KL(g, h(y, \hat{\phi}))$ .

## Akaike

- Seja  $k$  o índice do modelo ( $k = 1$  ou  $k = 2$ , em nosso exemplo, mas podemos ter vários modelos ao mesmo tempo)
- Seja  $p_k$  o número de parâmetros livres do modelo  $k$ .
- Ele mostrou que, se calcularmos o valor de

$$AIC(k) = -2 \log f(\mathbf{y}, \hat{\theta}_k) + 2p_k$$

para cada modelo alternativo, o que tiver o menor  $AIC(k)$  deve ser o melhor modelo.

# Usando o AIC na prática

- Quando temos vários modelos candidatos, com diferentes estruturas ou números de variáveis explicativas, o AIC fornece uma regra objetiva para comparação.
- Para cada modelo  $k$ , calculamos:

$$AIC(k) = -2 \log f(\mathbf{y}; \hat{\theta}_k) + 2p_k$$

- O modelo com menor valor de AIC é considerado o melhor.
- Podemos comparar modelos com diferentes conjuntos de variáveis, diferentes distribuições, ou até diferentes formas funcionais.
- Importante: todos os AICs devem ser calculados com a mesma resposta  $\mathbf{y}$  sobre o mesmo conjunto de dados.

## Exemplo: regressão linear múltipla

- Suponha que queremos modelar o consumo de energia  $Y$  com base em variáveis como temperatura ( $X_1$ ), umidade ( $X_2$ ), e velocidade do vento ( $X_3$ ).
- Ajustamos três modelos lineares:
  - Modelo 1:  $Y = \beta_0 + \beta_1 X_1$
  - Modelo 2:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2$
  - Modelo 3:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$
- A log-verossimilhança de cada modelo avaliada no MLE será proporcional ao MSE de cada modelo.
- Se olharmos o MSE dos três modelos o modelo mais completo terá menor MSE.
- Por quê?

## Exemplo: regressão linear múltipla

- Ajustamos três modelos lineares:
  - Modelo 1:  $Y = \beta_0 + \beta_1 X_1$
  - Modelo 2:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2$
  - Modelo 3:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$
- Calculamos o AIC para os três modelos:

$$AIC(k) = -2 \log f(\mathbf{y}; \hat{\boldsymbol{\theta}}_k) + 2p_k$$

- Mesmo que o Modelo 3 tenha maior log-verossimilhança, o AIC pode indicar que o Modelo 2 é melhor (trade-off ajuste vs. complexidade).
- Isso evita overfitting e melhora a capacidade preditiva em novos dados.

## Exemplo: regressão logística

- Agora, a variável resposta  $Y$  indica se houve ou não falha em um equipamento:  $Y = 1$  (falha),  $Y = 0$  (sem falha).
- Ajustamos três modelos logísticos:
  - Modelo 1:  $\log \frac{p}{1-p} = \beta_0 + \beta_1 X_1$
  - Modelo 2:  $\log \frac{p}{1-p} = \beta_0 + \beta_1 X_1 + \beta_2 X_2$
  - Modelo 3:  $\log \frac{p}{1-p} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$
- Para cada modelo, usamos a log-verossimilhança da regressão logística e computamos o AIC.
- Mesmo raciocínio: menor AIC  $\rightarrow$  melhor equilíbrio entre ajuste e complexidade.
- A abordagem funciona mesmo com modelos de natureza não linear.

# Ideia teórica por trás do AIC

- O objetivo de Akaike era comparar os valores mínimos de  $KL(g, f(y; \theta))$  para diferentes modelos.
- Como vimos:

$$KL(g, f(y; \theta)) = \mathbb{E}_g[\log g(Y)] - \mathbb{E}_g[\log f(Y; \theta)]$$

- Como  $\mathbb{E}_g[\log g(Y)]$  é constante (não depende do modelo), basta comparar:

$$-\min_{\theta} \mathbb{E}_g[\log f(Y; \theta)] = -\mathbb{E}_g[\log f(Y; \theta_0)]$$

de cada modelo.

- Mas este valor não é observável diretamente pois não conhecemos  $\theta_0$ .
- temos apenas uma estimativa de  $\theta_0$  baseada no MLE  $\hat{\theta}$ .

# Como Akaike resolveu os dois problemas?

- Akaike mostrou que o valor observado da log-verossimilhança avaliada no MLE:

$$\log f(\mathbf{y}; \hat{\theta})$$

é uma estimativa viciada de

$$\mathbb{E}_g[\log f(Y; \theta_0)]$$

onde  $\theta_0$  é o valor ótimo de acordo com KL.

- Defina o viés:

$$\mathbb{E}_g[\log f(\mathbf{y}; \hat{\theta})] - \mathbb{E}_g[\log f(Y; \theta_0)]$$

- Ele obteve uma correção assintótica para esse viés, proporcional ao número de parâmetros  $p_k$  do modelo.

## Como Akaike corrigiu o viés?

- Akaike mostrou que, assintoticamente, esse viés é aproximadamente igual a:

$$\text{Viés} \approx p_k$$

onde  $p_k$  é o número de parâmetros do modelo.

- Isso significa que a log-verossimilhança observada tende a superestimar o desempenho preditivo fora da amostra.
- Para corrigir esse viés, Akaike propôs o **Akaike Information Criterion (AIC)**:

$$\text{AIC} = -2 \log f(\mathbf{y}; \hat{\theta}) + 2p_k$$

- O termo  $2p_k$  penaliza o excesso de complexidade e ajusta a superestimação da log-verossimilhança.
- O AIC permite comparar modelos com diferentes números de parâmetros, favorecendo os mais parcimoniosos com bom ajuste.

# Como Akaike resolveu os dois problemas?

- Assim nasceu o critério:

$$AIC(k) = -2 \log f(\mathbf{y}; \hat{\theta}_k) + 2p_k$$

- O AIC é uma estimativa assintoticamente não-viesada de  $-2 \cdot \mathbb{E}_g[\log f(Y; \theta_0)]$ , onde  $\hat{\theta}$  é uma aproximação de  $\theta_0$  obtida via MLE.
- O AIC aproxima  $-2 \cdot \mathbb{E}_g[\log f(Y; \theta_0)]$ , isto é, mede a perda de informação esperada ao usar o modelo  $f(y; \theta)$  no lugar de  $g$ .
- O modelo com menor AIC é o mais próximo de  $g$  em termos de KL.

## Otimismo da log-verossimilhança

- Mesmo quando o modelo está corretamente especificado (isto é,  $g = f(y; \theta_0)$  para algum  $\theta_0$ ), o MLE maximiza a verossimilhança:

$$L(\hat{\theta}) = \log f(\mathbf{y}; \hat{\theta}) \geq \log f(\mathbf{y}; \theta_0)$$

- Isso acontece porque  $\hat{\theta}$  foi escolhido para maximizar a verossimilhança nos dados observados.
- Assim, o valor observado  $L(\hat{\theta})$  é um estimador viciado para cima de  $\mathbb{E}_g[\log f(Y; \theta_0)]$ .
- Akaike mostrou que essa mesma ideia vale mesmo quando o modelo está mal especificado, e a distribuição verdadeira  $g$  não pertence à família  $\{f(y; \theta)\}$ .

# Esboço da demonstração de Akaike

- $Y_1, \dots, Y_n$  são i.i.d. com distribuição verdadeira  $g$ .
- Defina o MLE:

$$\hat{\theta} = \arg \max_{\theta} \sum_{i=1}^n \log f(Y_i; \theta)$$

- Nossa objetivo é estimar:

$$-2 \cdot \mathbb{E}_g[\log f(Y; \theta_0)]$$

- Mas só temos acesso a  $L(\hat{\theta}) = \log f(\mathbf{y}; \hat{\theta})$ .
- Usando expansão de Taylor de segunda ordem de  $\log f(Y; \hat{\theta})$  em torno de  $\theta_0$ , e resultados assintóticos do MLE, vamos mostrar que:

$$\mathbb{E}_g \left[ \log f(\mathbf{y}; \hat{\theta}) \right] = n \cdot \mathbb{E}_g[\log f(Y; \theta_0)] + p + o(1)$$

# Expansão de Taylor da log-verossimilhança

- Vamos expandir  $\log f(Y; \hat{\theta})$  em torno de  $\theta_0$  usando Taylor de segunda ordem:

$$\begin{aligned}\log f(Y; \hat{\theta}) \approx & \log f(Y; \theta_0) + (\hat{\theta} - \theta_0)^\top \nabla_{\theta} \log f(Y; \theta_0) \\ & + \frac{1}{2} (\hat{\theta} - \theta_0)^\top \nabla_{\theta}^2 \log f(Y; \theta_0) (\hat{\theta} - \theta_0)\end{aligned}$$

- vamos poder ignorar o segundo termo, como explicamos agora.
- A expectativa de  $\nabla_{\theta} \log f(Y; \theta_0)$  sob  $g$  é zero (por definição de  $\theta_0$ ).
- Vamos demonstrar isso a seguir.

## Mesmo com modelo errado: o score tem média zero

- Seja  $g(y)$  a densidade verdadeira e  $f(y; \theta)$  a densidade do modelo.
- Defina:

$$\ell(\theta) = \mathbb{E}_g[\log f(Y; \theta)] = \int \log f(y; \theta) \cdot g(y) dy$$

- Suponha que  $\ell(\theta)$  é diferenciável e que podemos trocar derivada e integral:

$$\nabla_{\theta} \ell(\theta) = \int \nabla_{\theta} \log f(y; \theta) \cdot g(y) dy$$

- Seja  $\theta_0 = \arg \max_{\theta} \ell(\theta)$ , ou seja, o valor que minimiza a divergência KL entre  $g$  e o modelo.
- Então:

$$\mathbb{E}_g[\nabla_{\theta} \log f(Y; \theta_0)] = \nabla_{\theta} \ell(\theta_0) = 0$$

- Mesmo com o modelo errado, o score tem esperança nula em  $\theta_0$ .

# Por que o termo linear da expansão pode ser ignorado?

- Na expansão de Taylor de  $\log f(Y; \hat{\theta})$  em torno de  $\theta_0$  aparece o termo:

$$(\hat{\theta} - \theta_0)^\top \nabla_{\theta} \log f(Y; \theta_0)$$

- Este é o produto de dois termos aleatórios, e não podemos separar a esperança:

$$\mathbb{E}_g[(\hat{\theta} - \theta_0)^\top \nabla_{\theta} \log f(Y; \theta_0)] \neq (\mathbb{E}_g[\hat{\theta} - \theta_0])^\top \cdot \mathbb{E}_g[\nabla_{\theta} \log f(Y; \theta_0)]$$

- Porém:

- $\hat{\theta} - \theta_0 = \mathcal{O}_p(n^{-1/2})$
- $\nabla_{\theta} \log f(Y; \theta_0)$  é  $\mathcal{O}_p(1)$  e tem média zero
- Os dois termos são assintoticamente (quase) independentes

- Resultado:

$$\mathbb{E}_g \left[ (\hat{\theta} - \theta_0)^\top \nabla_{\theta} \log f(Y; \theta_0) \right] = o(n^{-1})$$

- Podemos ignorar esse termo na análise assintótica do viés do AIC.

## Consequência da expansão de Taylor

- A variância de  $\hat{\theta}$  em torno de  $\theta_0$  é da ordem de  $1/n$  e tende para a inversa da informação de Fisher.
- Assim, ao tomar a esperança em  $g$ , o primeiro termo de ordem não nula vem do termo quadrático da expansão.
- Para o segundo termo, temos uma forma quadrática que se aproxima de uma distribuição qui-quadrado. Seu valor esperado é a dimensão do vetor.

## Consequência da expansão de Taylor

- Assim, a expectativa da log-verossimilhança avaliada em  $\hat{\theta}$  é então:

$$\mathbb{E}_g[\log f(Y; \hat{\theta})] \approx \mathbb{E}_g[\log f(Y; \theta_0)] + \frac{p}{n}$$

- Multiplicando por  $n$ , temos:

$$\mathbb{E}_g[\log f(\mathbf{y}; \hat{\theta})] \approx n \cdot \mathbb{E}_g[\log f(Y; \theta_0)] + p$$

- Logo, o valor observado da log-verossimilhança é otimista, ele está em média  $p$  unidades acima do valor esperado verdadeiro.
- Esse viés é justamente o que é compensado pelo termo  $+2p$  no AIC.

## Conclusão: o viés e o AIC

- O viés é, aproximadamente:

$$\mathbb{E}_g[\log f(\mathbf{y}; \hat{\theta})] - n \cdot \mathbb{E}_g[\log f(Y; \theta_0)] \approx p$$

- Multiplicando por  $-2$ , temos:

$$-2 \cdot \log f(\mathbf{y}; \hat{\theta}) + 2p \approx -2 \cdot \mathbb{E}_g[\log f(Y; \theta_0)] + \text{constante}$$

- Portanto, o critério

$$AIC = -2 \cdot \log f(\mathbf{y}; \hat{\theta}) + 2p$$

é uma estimativa assintoticamente não-viesada (até constante aditiva) de  $-2 \cdot \mathbb{E}_g[\log f(Y; \theta_0)]$ .

- Mínimo AIC  $\rightarrow$  modelo mais próximo da distribuição verdadeira  $g$  em termos de KL.