Information and Coding Theory MA41024/ MA60020/ MA60262

Bibhas Adhikari

Spring 2022-23, IIT Kharagpur

Lecture 6 January 23, 2023

э

(B)

Also known as *relative entropy* is a measure of how different two distributions are.

Also known as *relative entropy* is a measure of how different two distributions are.

Definition Let P and and Q be be two distributions on a sample space  $\mathcal{X}$ . The KL-divergence between P and Q is defined as:

$$D(P||Q) = \sum_{x \in \mathcal{X}} p(x) \log\left(\frac{p(x)}{q(x)}\right)$$

A B A A B A

2/6

Also known as *relative entropy* is a measure of how different two distributions are.

Definition Let P and and Q be be two distributions on a sample space  $\mathcal{X}$ . The KL-divergence between P and Q is defined as:

$$D(P \| Q) = \sum_{x \in \mathcal{X}} p(x) \log \left( \frac{p(x)}{q(x)} \right)$$

Example Suppose  $\mathcal{X} = \{a, b, c\}$  with  $p(x) = \frac{1}{3}$ ,  $x \in \mathcal{X}$  and  $q(a) = \frac{1}{2}$ ,  $q(b) = \frac{1}{2}$ , q(c) = 0. Then

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Also known as *relative entropy* is a measure of how different two distributions are.

Definition Let P and and Q be be two distributions on a sample space  $\mathcal{X}$ . The KL-divergence between P and Q is defined as:

$$D(P||Q) = \sum_{x \in \mathcal{X}} p(x) \log\left(\frac{p(x)}{q(x)}\right)$$

Example Suppose  $\mathcal{X} = \{a, b, c\}$  with  $p(x) = \frac{1}{3}$ ,  $x \in \mathcal{X}$  and  $q(a) = \frac{1}{2}$ ,  $q(b) = \frac{1}{2}$ , q(c) = 0. Then

$$D(P||Q) = \frac{2}{3}\log\frac{2}{3} + \infty = \infty$$
$$D(Q||P) = \log\frac{3}{2} + 0 = \log\frac{3}{2}$$

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

 $ightarrow D(P\|Q)$  and  $D(Q\|P)$  are necessarily equal

< A 1

э

A B A A B A

- $\rightarrow D(P \| Q)$  and  $D(Q \| P)$  are necessarily equal
- $\rightarrow D(P \| Q)$  may be infinite

э

- $\rightarrow D(P \| Q)$  and  $D(Q \| P)$  are necessarily equal
- $\rightarrow D(P \| Q)$  may be infinite
- $\rightarrow$  Let  $Supp(P) = \{x : p(x) > 0\}$ . Then we must have  $Supp(P) \subseteq Supp(Q)$  if  $D(P||Q) < \infty$

3

- $ightarrow \ D(P\|Q)$  and  $D(Q\|P)$  are necessarily equal
- $ightarrow D(P\|Q)$  may be infinite
- → Let  $Supp(P) = \{x : p(x) > 0\}$ . Then we must have  $Supp(P) \subseteq Supp(Q)$  if  $D(P||Q) < \infty$

Even though the KL-divergence is not symmetric, it is often used as a measure of "dissimilarity" between two distributions

▶ < ∃ >

- $ightarrow \ D(P\|Q)$  and  $D(Q\|P)$  are necessarily equal
- $ightarrow D(P\|Q)$  may be infinite
- → Let  $Supp(P) = \{x : p(x) > 0\}$ . Then we must have  $Supp(P) \subseteq Supp(Q)$  if  $D(P||Q) < \infty$

Even though the KL-divergence is not symmetric, it is often used as a measure of "dissimilarity" between two distributions

Lemma Let P and Q be distributions on a finite space  $\mathcal{X}$ . Then  $D(P||Q) \ge 0$  with equality if and only if P = Q.

くぼう くほう くほう しほ

- $ightarrow \ D(P\|Q)$  and  $D(Q\|P)$  are necessarily equal
- $ightarrow D(P\|Q)$  may be infinite
- → Let  $Supp(P) = \{x : p(x) > 0\}$ . Then we must have  $Supp(P) \subseteq Supp(Q)$  if  $D(P||Q) < \infty$

Even though the KL-divergence is not symmetric, it is often used as a measure of "dissimilarity" between two distributions

Lemma Let P and Q be distributions on a finite space  $\mathcal{X}$ . Then  $D(P||Q) \ge 0$  with equality if and only if P = Q.

$$D(P||Q) = \sum_{x} p(x) \log \frac{p(x)}{q(x)} = \sum_{x \in Supp(P)} p(x) \log \frac{p(x)}{q(x)}$$
$$\geq -\log \left( \sum_{x \in Supp(P)} p(x) \cdot \frac{q(x)}{p(x)} \right)$$
$$= -\log \left( \sum_{x \in Supp(P)} q(x) \right) \geq -\log 1 = 0$$

Homework When D(P||Q) = 0 implies p(x) = q(x) for all  $x \in Supp(P)$ , which gives  $p(x) = q(x) \ \forall x \in \mathcal{X}$ 

3

イロト イポト イヨト イヨト

Homework When D(P||Q) = 0 implies p(x) = q(x) for all  $x \in Supp(P)$ , which gives  $p(x) = q(x) \ \forall x \in \mathcal{X}$ 

Chain rule for KL-divergence Let P(X, Y) and Q(X, Y) be two distributions for a pair of variables X and Y. Then,

 $D(P(X,Y) \| Q(X,Y))$ 

- $= D(P(X) || Q(X)) + \mathbb{E}_{x}[D(P(Y|X = x) || Q(Y|X = x))]$
- = D(P(X) || Q(X)) + D(P(Y|X) || Q(Y|X))

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x, y) \log \frac{p(x, y)}{q(x, y)}$$

2

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x, y) \log \frac{p(x, y)}{q(x, y)}$$

$$= \sum_{x,y} p(x) p(y|x) \log \left(\frac{p(x)}{q(x)} \cdot \frac{p(y|x)}{q(y|x)}\right)$$

2

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x,y) \log \frac{p(x,y)}{q(x,y)}$$

$$= \sum_{x,y} p(x) p(y|x) \log \left(\frac{p(x)}{q(x)} \cdot \frac{p(y|x)}{q(y|x)}\right)$$

$$= \sum_{x} p(x) \log \frac{p(x)}{q(x)} \sum_{y} p(y|x) + \sum_{x} p(x) \sum_{y} p(y|x) \log \frac{p(y|x)}{q(y|x)}$$

2

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x, y) \log \frac{p(x, y)}{q(x, y)}$$

$$= \sum_{x,y} p(x) p(y|x) \log \left(\frac{p(x)}{q(x)} \cdot \frac{p(y|x)}{q(y|x)}\right)$$

$$= \sum_{x} p(x) \log \frac{p(x)}{q(x)} \sum_{y} p(y|x) + \sum_{x} p(x) \sum_{y} p(y|x) \log \frac{p(y|x)}{q(y|x)}$$

$$= D(P(X) || Q(X)) + \sum_{x} p(x) \cdot D(P(Y|X = x)) || Q(Y|X = x))$$

2

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x,y) \log \frac{p(x,y)}{q(x,y)}$$

$$= \sum_{x,y} p(x) p(y|x) \log \left(\frac{p(x)}{q(x)} \cdot \frac{p(y|x)}{q(y|x)}\right)$$

$$= \sum_{x} p(x) \log \frac{p(x)}{q(x)} \sum_{y} p(y|x) + \sum_{x} p(x) \sum_{y} p(y|x) \log \frac{p(y|x)}{q(y|x)}$$

$$= D(P(X) || Q(X)) + \sum_{x} p(x) \cdot D(P(Y|X = x)) || Q(Y|X = x))$$

$$= D(P(X) || Q(x)) + D(P(Y|X) || Q(Y|X))$$

э

A D N A B N A B N A B N

$$D(P(X, Y) || Q(X, Y))$$

$$= \sum_{x,y} p(x, y) \log \frac{p(x, y)}{q(x, y)}$$

$$= \sum_{x,y} p(x) p(y|x) \log \left(\frac{p(x)}{q(x)} \cdot \frac{p(y|x)}{q(y|x)}\right)$$

$$= \sum_{x} p(x) \log \frac{p(x)}{q(x)} \sum_{y} p(y|x) + \sum_{x} p(x) \sum_{y} p(y|x) \log \frac{p(y|x)}{q(y|x)}$$

$$= D(P(X) || Q(X)) + \sum_{x} p(x) \cdot D(P(Y|X = x)) || Q(Y|X = x))$$

$$= D(P(X) || Q(x)) + D(P(Y|X) || Q(Y|X))$$
Note If  $P(X, Y) = P_1(X)P_2(Y)$  and  $Q(X, Y) = Q_1(X)Q_2(Y)$  then  
 $D(P||Q) = D(P_1||Q_1) + D(P_2||Q_2)$ 

3

<ロト <問ト < 目と < 目と

Interpretation of KL divergence in terms of source coding

$$D(P||Q) = \sum_{x} p(x) \log \frac{p(x)}{q(x)} = \sum_{x} p(x) \log \frac{1}{q(x)} - \sum_{x} p(x) \log \frac{1}{p(x)}$$

э

∃ ► < ∃ ►</p>

Interpretation of KL divergence in terms of source coding

$$D(P||Q) = \sum_{x} p(x) \log \frac{p(x)}{q(x)} = \sum_{x} p(x) \log \frac{1}{q(x)} - \sum_{x} p(x) \log \frac{1}{p(x)}$$

 $\rightarrow$  This can be interpreted as the number of extra bits we use (on average) if we designed a code according to the distribution *P*, but used it to communicate outcomes of a random variable *X* distributed according to *Q* 

Interpretation of KL divergence in terms of source coding

$$D(P||Q) = \sum_{x} p(x) \log \frac{p(x)}{q(x)} = \sum_{x} p(x) \log \frac{1}{q(x)} - \sum_{x} p(x) \log \frac{1}{p(x)}$$

- $\rightarrow$  This can be interpreted as the number of extra bits we use (on average) if we designed a code according to the distribution P, but used it to communicate outcomes of a random variable X distributed according to Q
- $\rightarrow$  The first term in the RHS, which corresponds to the average number of bits used by the "wrong" encoding, is also referred to as cross entropy