

2019年5月20日（川端）

データ圧縮基礎資料

## 8 レート歪関数の計算（離散分布の場合）

本節では、離散定常無記憶情報源  $X^n, p_{X^n}(x^n) = \prod_{l=1}^n p_X(x_l)$  のレート歪み関数

$$R(D) = \inf_{p_{Y|X}: E[\rho(X,Y)] \leq D} I(p_X, p_{Y|X}) \quad (1)$$

の計算について述べる。（ただし、 $I(p_X, p_{Y|X})$  は  $I(X;Y)$  のことである。）

### 8.1 ハミング歪に対する二値情報源の R(D)

**定理 1** 情報源アルファベットを  $\mathcal{X} = \{0, 1\}$ ，再生アルファベットを  $\mathcal{Y} = \{0, 1\}$  とする．歪はハミング歪すなわち  $\rho(x, y) = x \oplus y$  とする． $\mathcal{X}$  上の二値定常無記憶情報源を確率分布が  $p = p_X(1) = 1 - p_X(0)$  となるように与える．このとき、

$$R(D) = \begin{cases} h(p) - h(D) & \text{if } D \leq p \\ 0 & \text{if } D > p \end{cases}$$

**証明:** まず  $p \leq 1/2$  の場合を証明する．

$$\begin{aligned} I(X;Y) &= H(X) - H(X|Y) \\ &= h(p) - H(X \oplus Y|Y) \\ &\geq h(p) - H(X \oplus Y) \quad (\text{等号条件は } X \oplus Y \perp Y) \end{aligned} \quad (2)$$

$$= h(p) - h(E(X \oplus Y)) \quad (3)$$

まず、 $D \leq p$  の場合を考える．このとき

$$(3) \geq h(p) - h(D) \quad (\text{等号には } E(X \oplus Y) = D \text{ が必要}) \quad (4)$$

が成立する．以上の等号条件を同時に満たす  $Y$  が存在することが等号のための必要十分条件である． $X = Y \oplus (Y \oplus X)$  に注意すると (2) の等号条件は、入力  $Y$  に独立な加法的雑音  $Y \oplus X$  が加わる二元対称通信路の出力が  $X$  であることと同じである． $E(X \oplus Y) = D$  のとき、交差確率は  $D$  である． $r = P(Y = 1)$  と定義すると、以上の条件は

$$\begin{bmatrix} 1-r & r \end{bmatrix} \begin{bmatrix} 1-D & D \\ D & 1-D \end{bmatrix} = \begin{bmatrix} 1-p & p \end{bmatrix}$$

と書ける．これは

$$D(1-r) + r(1-D) = p$$

と同じであるから、 $r$  について解くと

$$r = \frac{p-D}{(1-D)-D},$$

となる．仮定した  $D \leq p$  の範囲では  $r$  が確率として存在していることがわかり、この範囲で定理が示された．

次に、 $D > p$  の場合を考えると、

$$(3) \geq 0 \quad ((2) \text{ の等号条件と合わせて、等号は } Y \text{ が定数 } 0 \text{ であるときに成立})$$

がいえるので、この範囲で定理が示された．

$p \geq 1/2$  のときには  $\mathcal{X}, \mathcal{Y}$  の 2 つの記号を同時に交換すれば上の議論がそのまま成り立つ．従って結果は変わらない．証明終

## 8.2 Lagrange 乗数を用いた $R(D)$ に対する表現と Arimoto-Brahut 法

$R(D)$  に対する (1) の表現は,  $E\rho(X, Y) \leq D$  に対する Lagrange 未定乗数  $s \leq 0$  を固定すると, 以下の最小化問題として表現できる.

$$R(D) = sD + \min_{q_Y} \min_{p_{Y|X}} \left[ \sum_x \sum_y p_X(x) p_{Y|X}(y|x) \log \frac{p_{Y|X}(y|x)}{q_Y(y) \exp_2(s\rho(x, y))} \right] \quad (5)$$

$s$  は Kuhn-Tucker 条件すなわち, 最小値を達成する  $p_{Y|X}^*$  に対しては  $D \geq \sum_x \sum_y p_X(x) p_{Y|X}^*(y|x) \rho(x, y)$  を満足する必要がある, 特に不等号が厳密である場合には  $s = 0$  である必要がある. (以上を満たせば最適性の十分条件であることも知られている.)

そこで負の  $s$  に対して, (5) における  $D$  を  $D_s = \sum_x \sum_y p_X(x) p_{Y|X}^*(y|x) \rho(x, y)$  と書いておくことにする. (5) の最適化は 2 重最小化問題になっている.

まず  $p_{Y|X}$  固定の下で  $\min_{q_Y}$  を実行すると  $q_Y^*(\cdot) = \sum_x p_X(x) p_{Y|X}(\cdot|x)$  において最小値

$$R(D_s) = I(p_X, p_{Y|X}) \quad (6)$$

がえられる. また,  $q_Y$  固定の下で  $\min_{p_{Y|X}}$  を実行すると  $p_{Y|X}^*(y|x) = \frac{q_Y(y) \exp_2\{s\rho(x, y)\}}{\sum_y q_Y(y) \exp_2\{s\rho(x, y)\}}$  において最小値

$$R(D_s) = sD_s + \min_{q_Y} \left[ \sum_x p_X(x) \log \left( \sum_y q_Y(y) \exp_2(s\rho(x, y)) \right)^{-1} \right] \quad (7)$$

が得られる. このときも, やはり, 最小値を達成する  $p_{Y|X}^*$  を用いて  $D_s = \sum_x \sum_y p_X(x) p_{Y|X}^*(y|x) \rho(x, y)$ . が成り立つものとしてよい.

最小化 (6) および最小化 (7) を繰り返すことで  $R(D_s)$  に対する単調減少する上界が得られるが, この上界は  $R(D_s)$  に収束することも知られている. これを Arimoto-Brahut アルゴリズムという.

## 8.3 $R(D)$ に対する双対最適化

次に,  $R(D_s)$  には, 以下の双対表現がある.

$$R(D_s) = \max_{\lambda(\cdot) \in \Lambda_s} \left( sD + \sum_x p_X(x) \log \lambda(x) \right)$$

ただし,

$$\Lambda_s := \{ \lambda(\cdot) : (\forall x) (\lambda(x) \geq 0), \quad (\forall y) \left( \sum_x p_X(x) \lambda(x) \exp_2 s\rho(x, y) \leq 1 \right) \}$$

証明: まず  $\lambda(\cdot) \in \Lambda_s$  について

$$R(D_s) \geq sD_s + \sum_x p_X(x) \log \lambda(x)$$

を示そう. 左辺引く右辺は

$$\begin{aligned} I(X; Y) - sD - \sum_x p_X(x) \log \lambda(x) &= \sum_x \sum_y p_X(x) p_{Y|X}(y|x) \log \frac{p_{Y|X}(y|x)}{q_Y(y) \lambda(x) \exp_2(s\rho(x, y))} \\ &= \sum_x \sum_y p_X(x) p_{Y|X}(y|x) \log \frac{p_X(x) p_{Y|X}(y|x)}{p_X(x) q_Y(y) \lambda(x) \exp_2(s\rho(x, y))} \\ &\geq \log \frac{1}{\sum_y q_Y(y) (\sum_x p_X(x) \lambda(x) \exp_2(s\rho(x, y)))} \\ &\geq 0 \end{aligned} \quad (8)$$

最初の不等式は Log 和不等式を用いた。次に、等号の達成を示そう。(7)の最小化を与える  $q_Y$  を  $q_Y^*$  とし

$$\lambda(x) := \left( \sum_y q_Y^*(y) \exp_2(s\rho(x, y)) \right)^{-1}$$

と定義すると  $p_{Y|X}^*(y|x)p_X(x)/q_Y^*(y)$  が  $\mathcal{X}$  上の確率分布であることから

$$\sum_x p_X(x) \lambda(x) \exp_2 s\rho(x, y) = 1$$

が成り立つが、この  $\lambda(x)$  を用いると、

$$R(D_s) := sD_s + \sum_x p_X(x) \log \lambda(x)$$

と書けている。証明終