

# 挿入や削除を訂正する符号の サイズの上界・下界

安永 憲司

東京工業大学

エクспанダーグラフの新しい構成手法の確立とその応用2 @九州大学 IMI

2023.9.7

# 自己紹介

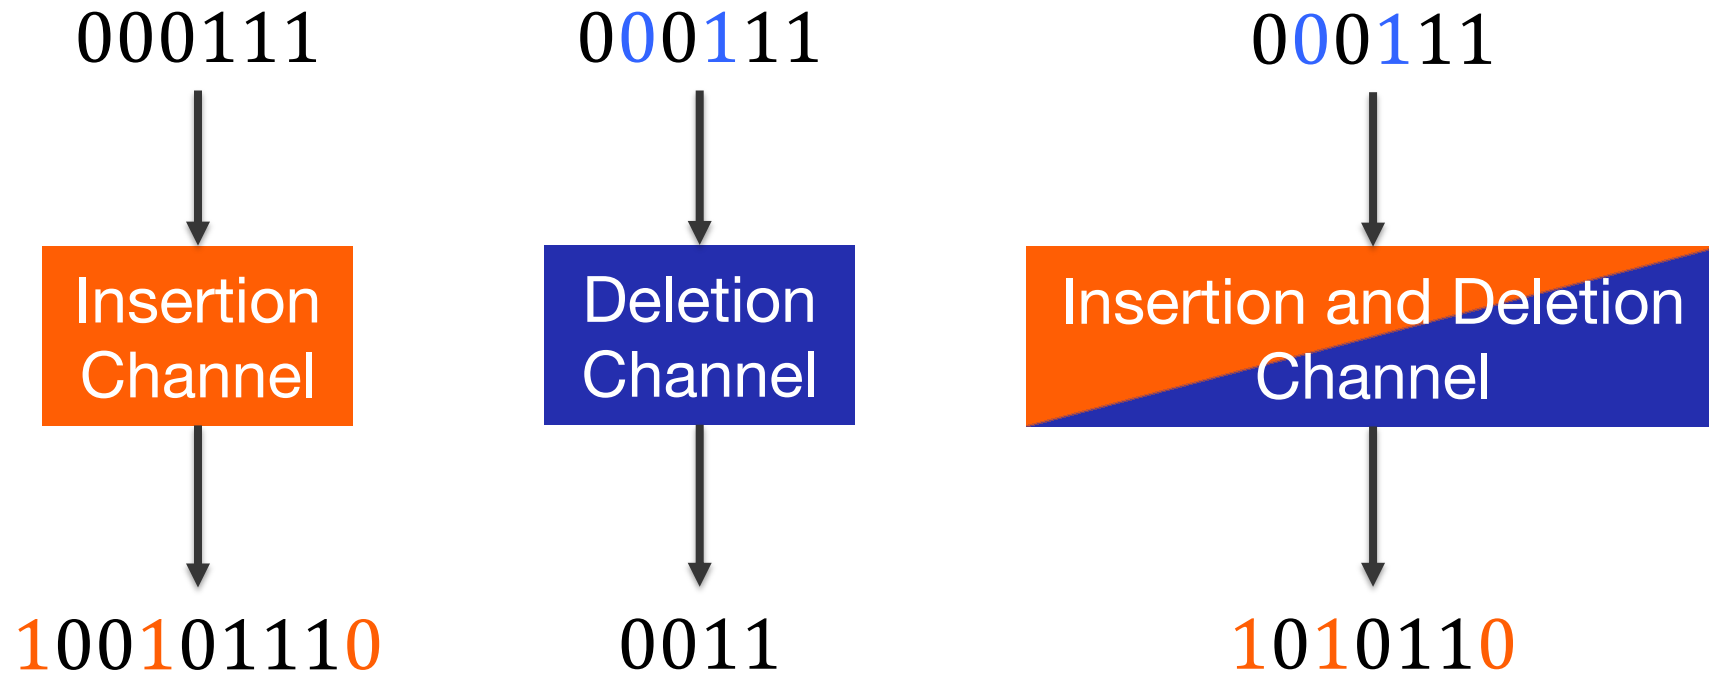
名前：安永 憲司

所属：東京工業大学 情報理工学院 数理・計算科学系

研究分野：理論計算機科学

- 主に，暗号理論
- 細々と，誤り訂正符号
- これから，計算量理論

# 挿入と削除



# Levenshtein 距離 (編集距離)

$d_L(x, y) := \min \{ x \text{ を } y \text{ に変換するのに必要な挿入・削除数} \}$

- 例.  $d_L(000, 111) = 6$ ,  $d_L(101, 010) = 2$
- $|x| = |y| = n$  のとき,  $0 \leq d_L(x, y) \leq 2n$
- $d_L(x, y) = |x| + |y| - 2\text{LCS}(x, y)$  (LCS( $x, y$ ):  $x$  と  $y$  の最長共通部分系列の長さ)

符号  $C$  の最小 Levenshtein 距離:  $d_L(C) := \min_{c_1 \neq c_2 \in C} d_L(c_1, c_2)$

$d_L(C) \geq d$  のとき,  $C$  は合計  $t \leq \lfloor \frac{d-1}{2} \rfloor$  個の挿入・削除を訂正できる

- $C \subseteq \Sigma^n$  のとき,  $d_L(C)$  は偶数で,  $t \leq \frac{d_L(C)}{2} - 1$  個を訂正できる
- 相対最小距離は  $\frac{d_L(C)}{2n} \in [0, 1]$
- 符号の相対最小距離  $\geq \delta \rightarrow \delta$  割合未満の挿入・削除を訂正

## 最良の符号サイズ $A_q(n, d)$

$$A_q(n, d) := \max\{ |C| : \exists C \subseteq \Sigma^n \text{ s.t. } |\Sigma| = q, d_L(C) \geq d \}$$

- $A_q(n, d)$  の上界  $\rightarrow$  符号として存在しない領域
- $A_q(n, d)$  の下界  $\rightarrow$  符号として存在しうる領域

### 漸近的な評価

- 符号列  $\{C_n\}_n$  の符号長  $n \rightarrow \infty$  の場合の振る舞いを評価
- $A_q(n, d)$  を達成する符号  $C \subseteq \Sigma^n$ ,  $|\Sigma| = q$  に対し,

符号化率  $R = \frac{\log_q |C|}{n}$  と 相対最小距離  $\delta = \frac{d_L(C)}{2n}$  の


トレードオフを明らかにしたい

# エクスペンダーグラフとの関わり

- Hamming 距離（通常の符号）
  - 定数レート符号で線形時間符号化・復号
  - 符号の最小距離の増幅
  - リスト復号可能符号との等価性
- Levenshtein 距離（挿入・削除訂正符号）
  - 直接的に関係する研究はこれまでない
  - 線形時間符号化・復号は未解決（距離を測るのに  $O(n^2)$ ）
  - 最小距離が増幅するかも不明


主結果のトレードオフ

# 符号化率と相対最小距離のトレードオフ： $q = 2$





# 符号化率と相対最小距離のトレードオフ： $q = 4$



## 基本的な事実 (1/2)

挿入球  $I_t(\mathbf{x}) := \{ \mathbf{x} \in \Sigma^n \text{ に } t \text{ 挿入してできる文字列 } \mathbf{y} \in \Sigma^{n+t} \}$

- $|I_t(\mathbf{x})| = \sum_{i=0}^t \binom{n+t}{i} (q-1)^i := I_q(n, t) \approx q^{(n+t)H_q\left(\frac{t}{n+t}\right)}$

削除球  $D_t(\mathbf{x}) := \{ \mathbf{x} \in \Sigma^n \text{ から } t \text{ 削除してできる文字列 } \mathbf{y} \in \Sigma^{n-t} \}$

- $|D_t(\mathbf{x})| \leq \binom{n}{t}$
- $\mathbf{x}$  のラン数  $= r(\mathbf{x}) \geq 2t$  のとき,  $\sum_{i=0}^t \binom{r(\mathbf{x})-t}{i} \leq |D_t(\mathbf{x})| \leq \binom{r(\mathbf{x})+t-1}{t}$ 
  - 例.  $r(0000) = 1, r(0011) = 2, r(0101) = 4$
- $R_q(n, r) := \{ \mathbf{x} \in \Sigma^n : r(\mathbf{x}) = r \}, |R_q(n, r)| = \binom{n-1}{r-1} q (q-1)^{r-1}$

## 基本的な事実 (2/2)

挿入削除球  $L_{t,s}(\mathbf{x}) := \{ \mathbf{x} \in \Sigma^n \text{ に } t \text{ 削除} \cdot s \text{ 挿入でできる文字列 } \mathbf{y} \in \Sigma^{n-t+s} \}$

- $L_{t,0}(\mathbf{x}) = D_t(\mathbf{x}), L_{0,t}(\mathbf{x}) = I_t(\mathbf{x})$

$|L_{t,t}(\mathbf{x})|$  の緊密な評価式は未解決問題

- $|L_{t,t}(\mathbf{x})| \leq |D_t(\mathbf{x})| \cdot I_q(n-t, t)$  が上界では最も良い??

二重数え上げ (double counting) より, 以下が成り立つ

$$\sum_{\mathbf{y} \in \Sigma^{n+t}} |D_t(\mathbf{y})| = \sum_{\mathbf{x} \in \Sigma^n} |I_t(\mathbf{x})| = q^n \cdot I_q(n, t)$$

符号サイズの上界

## 球充填 (sphere-packing) タイプの上界

**Theorem 1.** 最小 Levenshtein 距離  $d = 2(t + 1)$  の  $C \subseteq \Sigma^n$  に対し,

$$|C| \leq \left\lfloor \frac{q^{n+t}}{I_q(n, t)} \right\rfloor$$

証明：各  $c \in C$  に対し,  $I_t(c) \subseteq \Sigma^{n+t}$  は互いに交わらないため

**Corollary 1.** 最小 Levenshtein 距離  $\delta n$ , 符号化率  $R$  の  $C \subseteq \Sigma^n$  に対し,

$$R \leq (1 + \delta) \left( 1 - H_q \left( \frac{\delta}{1 + \delta} \right) \right) + o(1)$$

# 主結果その 1 : Elias タイプの上界

Theorem 2. 最小 Levenshtein 距離  $d < 2n$  の  $C \subseteq \Sigma^n$  について,

$$t < \frac{d}{2 - d/n}$$

を満たす任意の  $t \geq 0$  に対し,

$$|C| \leq \left[ \frac{(n+t)d}{(n+t)d - 2nt} \cdot \frac{q^{n+t}}{I_q(n, t)} \right]$$

Corollary 2. 最小 Levenshtein 距離  $\delta n$ , 符号化率  $R$  の  $C \subseteq \Sigma^n$  に対し,

$$R \leq \frac{1}{1 - \delta} \left( 1 - H_q(\delta) \right) + o(1)$$

## Theorem 2 の証明

- 二重数え上げを, 符号  $C$  との共通部分に適用すると,

$$\sum_{\mathbf{y} \in \Sigma^{n+t}} |D_t(\mathbf{y}) \cap C| = \sum_{\mathbf{x} \in C} |I_t(\mathbf{x})| = |C| \cdot I_q(n, t)$$

- ランダムに  $\mathbf{y} \in \Sigma^{n+t}$  を選ぶと,  $|D_t(\mathbf{y}) \cap C| \geq \frac{|C| \cdot I_q(n, t)}{q^{n+t}}$  を満たす  $\mathbf{y} \in \Sigma^{n+t}$  が存在
- $|D_t(\mathbf{y}) \cap C|$  は,  $t$  挿入に対するリスト復号のリストサイズ
- [Hayashi, Yasunaga (IEEE IT 2020)] のリスト復号可能性を適用
  - $t < \frac{d}{2-d/n}$  に対し,  $|D_t(\mathbf{y}) \cap C| \leq \frac{(n+t)d}{(n+t)d-2nt}$

## Hamming 距離の符号に対する上界の適用

符号  $C$  の最小 Hamming 距離  $\leq d$

Hamming 距離での  $A_q(n, d)$  の上界

→  $C$  の最小 Levenshtein 距離  $\leq 2d$

→ Levenshtein 距離での  $A_q(n, d)$  の上界

**Theorem 3.** 最小 Levenshtein 距離  $\delta n$ , 符号化率  $R$  の  $C \subseteq \Sigma^n$  に対し,


$$R \leq 1 - H_q(\theta - \sqrt{\theta(\theta - \delta)}) + o(1) \quad (\text{Elias 限界})$$

$$R \leq H_q\left(\frac{1}{q}(q - 1 - (q - 2)\delta - 2\sqrt{\delta(1 - \delta)(q - 1)})\right) + o(1) \quad (\text{MRRW 限界})$$


ここで,  $0 \leq \delta \leq \theta = 1 - \frac{1}{q}$



# 符号化率と相対最小距離のトレードオフ： $q = 2$



# 符号化率と相対最小距離のトレードオフ： $q = 4$






# 数值計算結果：上界

$q$	$n$	$d$	[Lev02]	[KK13]	Theorem 1	Theorem 2
2	20	4	97 453	55 206	95 325	181 643
2	20	10	26 456	2 535	1 295	2 452
2	20	20	190 416	1 059	32	28
2	20	30	961 048	—	5	4
2	40	4	47 498 012 376	28 192 605 878	52 357 696 560	102 167 009 660
2	40	10	1 279 636 864	9 880 934	117 292 187	228 473 245
2	40	20	1 122 371 648	3 203 459	215 900	203 859
2	40	30	13 097 807 352	298 539	3 735	1 195
2	40	40	287 193 094 240	1 048 713	231	43
4	20	4	30 003 945 118	19 289 677 788	68 719 476 736	90 174 299 388
4	20	10	360 221 648	25 002 768	306 647 351	316 287 316
4	20	20	536 774 720	1 645 315	1 258 226	79 926
4	20	30	192 278 071 952	—	34 771	71
4	40	4	$\approx 14\,843 \times 10^{18}$	$\approx 10\,332 \times 10^{18}$	$\approx 38\,997 \times 10^{18}$	$\approx 51\,574 \times 10^{18}$
4	40	10	$\approx 6\,113 \times 10^{15}$	$\approx 461\,805 \times 10^{12}$	$\approx 27\,238 \times 10^{15}$	$\approx 36\,015 \times 10^{15}$
4	40	20	$\approx 133\,526 \times 10^{12}$	$\approx 158\,374 \times 10^9$	$\approx 7\,269 \times 10^{12}$	$\approx 2\,172 \times 10^{12}$
4	40	40	$\approx 34\,641 \times 10^{15}$	$\approx 2\,123 \times 10^9$	$\approx 173\,431 \times 10^6$	$\approx 69 \times 10^6$
4	40	60	$\approx 306\,026 \times 10^{18}$	—	164 423 496	108

[KK13] A. A. Kulkarni and N. Kiyavash. Nonasymptotic upper bounds for deletion correcting codes. *IEEE Trans. Inf. Theory*, 59(8):5115–5130, 2013.

# [KK13] との漸近的な比較



[Hayashi, Yasunaga (IEEE IT 2020)] の  
リスト復号可能性

# List Decoding

- Decoder outputs a *small* list of codewords so that the list contains the transmitted codeword
- Extensively studied in Hamming metric
  - $\mathcal{C}$  is  $(t, \ell)$ -list decodable (in Hamming metric)
    - $\Leftrightarrow |B_H(\mathbf{v}, t) \cap \mathcal{C}| \leq \ell$  for any  $\mathbf{v} \in \Sigma^n$
    - $B_H(\mathbf{v}, t)$  : Hamming ball of radius  $t$  centered at  $\mathbf{v}$
    - $t$  : list-decoding radius,  $\ell$  : list size
- **Johnson bound** gives a bound on list size for  $t \geq d/2$

$$\ell \leq qnd \quad \text{if} \quad t < n - \sqrt{n(n-d)}$$

$q$  : alphabet size,  $d$  : minimum Hamming distance of  $\mathcal{C}$

# Our Results

- Johnson-type bound in Levenshtein metric is derived
  - The result by [Wachter-Zeh \(ISIT 2017\)](#) has some flaws
  - Our bound is obtained by a similar approach
- The bound implies that, as long as  $\ell = \text{poly}(n)$ ,
  - $\exists$  binary code of rate  $\Omega(1)$  correcting 0.707-frac. of insertions;
  - $\forall$  constant  $\tau_I > 0$  and  $\tau_D \in [0,1)$ ,  $\exists q$ -ary code of rate  $\Omega(1)$  and  $q = O(1)$  correcting  $\tau_I$ -frac. of ins. and  $\tau_D$ -frac. of del.
- Plotkin-type bound on code size in Levenshtein metric
  - By a simple application of Johnson-type bound

# (Main Technical Lemma) Johnson-type Bound

## Lemma 1

$C \subseteq \Sigma^n$  s.t.  $d_L(C) = d$

For non-negative integers  $t_I, t_D \leq n$ ,  $N = n + t_I - t_D$ ,  
and  $\mathbf{v} \in \Sigma^N$ , let

$$\ell := |B_L(\mathbf{v}, t_D, t_I) \cap C|.$$

$B_L(\mathbf{v}, t_D, t_I)$  : the set of words  
obtained from  $\mathbf{v}$  by  
 $\leq t_D$  insertions and  $\leq t_I$  deletions

$$\text{If } t_I < \left(\frac{d}{2} - t_D\right) \frac{n - t_D}{n - \frac{d}{2}}, \text{ then } \ell \leq \frac{N \binom{\frac{d}{2} - t_D}{N}}{\binom{\frac{d}{2} - t_D}{N} - t_I(n - t_D)}$$

( $t_I = t, t_D = 0$  とすると)

$$t < \frac{d}{2 - d/n} \text{ ならば, } |D_t(\mathbf{y}) \cap C| = \ell \leq \frac{(n+t)d}{(n+t)d - 2nt} \quad (\text{Theorem 2 で利用})$$



# Proof Idea


- Let  $\{\mathbf{c}_1, \dots, \mathbf{c}_\ell\}$  be the set of codewords that can be transformed to  $\mathbf{v}$  by  $t_I$  insertions and  $t_D$  deletions
- Consider the value  
 $\lambda :=$  Sum of pairwise distances between  $\ell$  codewords
- “Double Counting” is applied to  $\lambda$  :
  1. Row by row  $\rightarrow$  Lower bound from  $d_L(\mathbf{c}_i, \mathbf{c}_j) \geq d$
  2. Column by column  $\rightarrow$  Upper bound from  
 $d_L(\mathbf{c}_i, \mathbf{c}_j) \leq d_L(\mathbf{c}_i, \mathbf{v}) + d_L(\mathbf{v}, \mathbf{c}_j)$
- More sophisticated upper bound is used

# Proof of Theorem 1


- For  $\mathbf{v} \in \Sigma^N$ , let  $B_L(\mathbf{v}, t_D, t_I) \cap C = \{\mathbf{c}_1, \dots, \mathbf{c}_\ell\}$
- For each  $\mathbf{c}_i$ , define  $D^{(i)} \subseteq [n] = \{1, \dots, n\}$  and  $E^{(i)} \subseteq [N] = \{1, \dots, N\}$  s.t.  $\mathbf{c}_i$  can be transformed to  $\mathbf{v}$  by
  1. Deleting symbols in  $D^{(i)}$  from  $\mathbf{c}_i$ ; and
  2. Inserting symbols in  $E^{(i)}$



- We can choose s.t.  $|D^{(i)}| = t_D$ ,  $|E^{(i)}| = t_I$



- $c_i$  can be transformed to  $c_j$  by
  1. Deleting symbols in  $D^{(i)}$  from  $c_i$
  2. Inserting symbols in  $E^{(i)}$  to get  $v$
  3. Deleting symbols in  $E^{(j)}$  from  $v$
  4. Inserting symbols in  $D^{(j)}$  to get  $c_j$



- Steps 2-3 can be simplified as
  1. Deleting symbols in  $D^{(i)}$  from  $c_i$
  2. Inserting symbols in  $E^{(i)} \setminus E^{(j)}$  to get  $v_{|[N] \setminus (E^{(i)} \cap E^{(j)})}$
  3. Deleting symbols in  $E^{(j)} \setminus E^{(i)}$  from  $v_{|[N] \setminus (E^{(i)} \cap E^{(j)})}$
  4. Inserting symbols in  $D^{(j)}$  to get  $c_j$
- Thus, we have that

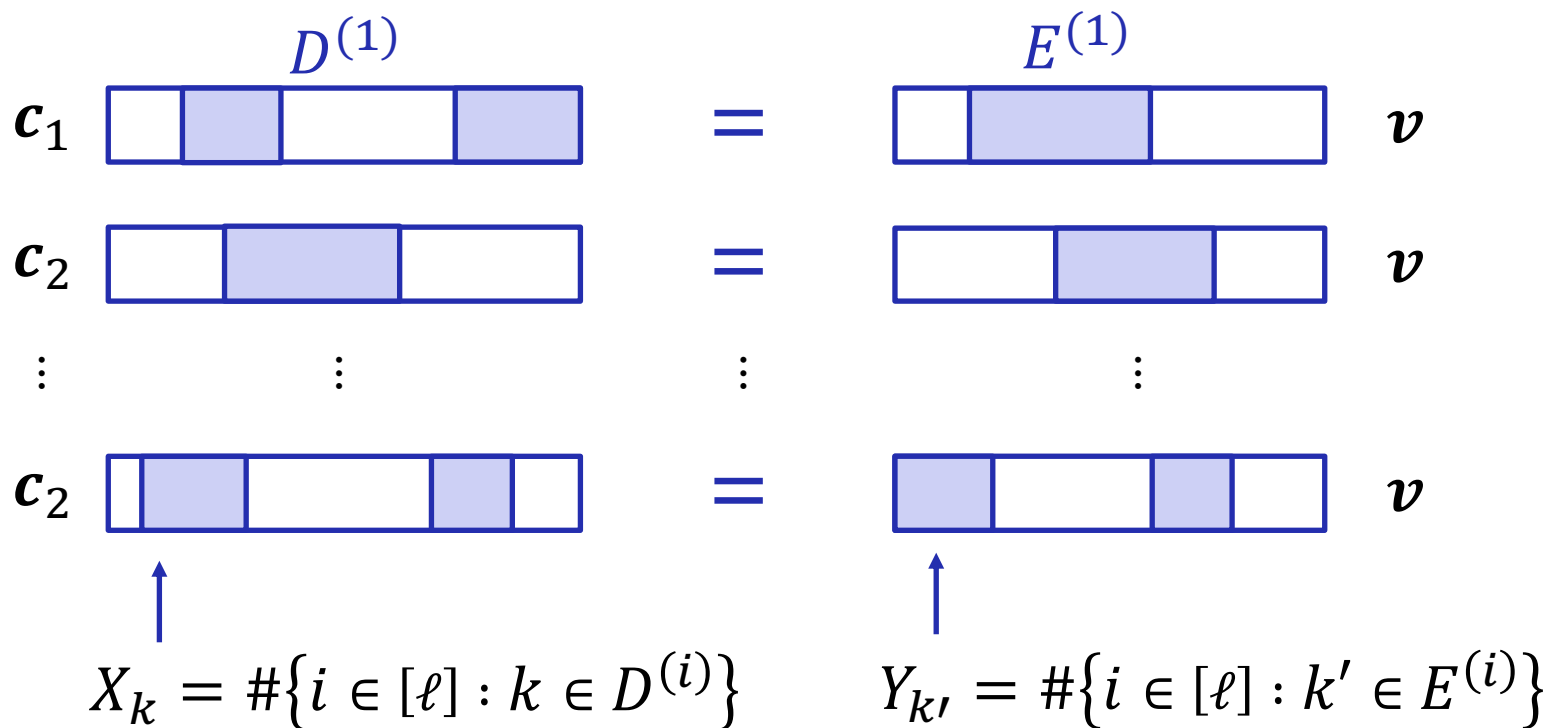
$$d_L(c_i, c_j) \leq |D^{(i)}| + |E^{(i)} \setminus E^{(j)}| + |E^{(j)} \setminus E^{(i)}| + |D^{(j)}|$$

- Define  $\lambda := \sum_{i \in [\ell]} \sum_{j \in [\ell] \setminus \{i\}} d_L(\mathbf{c}_i, \mathbf{c}_j)$
- We know that
  - $\lambda \geq \ell(\ell - 1)d$  (by  $d_L(\mathbf{c}_i, \mathbf{c}_j) \geq d$ )
  - $\lambda \leq \sum_{i \in [\ell]} \sum_{j \in [\ell] \setminus \{i\}} \left( \begin{array}{l} |D^{(i)}| + |E^{(i)} \setminus E^{(j)}| \\ + |E^{(j)} \setminus E^{(i)}| + |D^{(j)}| \end{array} \right)$
- Hence, we have
 
$$\ell(\ell - 1)d \leq \sum_{i \in [\ell]} \sum_{j \in [\ell] \setminus \{i\}} \left( \begin{array}{l} |D^{(i)}| + |E^{(i)} \setminus E^{(j)}| \\ + |E^{(j)} \setminus E^{(i)}| + |D^{(j)}| \end{array} \right)$$

- We can show that

- $\sum_{i \in [\ell]} \sum_{j \in [\ell] \setminus \{i\}} (|D^{(i)}| + |D^{(j)}|) = 2(\ell - 1) \sum_{k \in [n]} X_k$

- $\sum_{i \in [\ell]} \sum_{j \in [\ell] \setminus \{i\}} (|E^{(i)} \setminus E^{(j)}| + |E^{(j)} \setminus E^{(i)}|) = 2 \sum_{k' \in [N]} Y_{k'} (\ell - Y_{k'})$



- Thus, we have

$$\ell(\ell - 1)d \leq 2(\ell - 1) \sum_{k \in [n]} X_k + 2 \sum_{k' \in [N]} Y_{k'}(\ell - Y_{k'})$$

- By using  $\sum_{k \in [n]} X_k = \ell t_D$ ,  $\sum_{k' \in [N]} Y_{k'} = \ell t_I$ , we can show that

$$\ell \leq \frac{N \left( \frac{d}{2} - t_D \right)}{N \left( \frac{d}{2} - t_D \right) - t_I(n - t_D)}$$

- Both the numerator and the denominator are positive by the assumption.

**QED**

符号サイズの下界



## 平均球サイズによる下界

Tolhuizen (IEEE IT 1997).  $X$  上の距離関数  $\rho: X \times X \rightarrow \mathbb{Z}$  に対し,

- $x$  中心の半径  $d$  の球サイズ  $V_d(\mathbf{x}) := |\{\mathbf{y} \in X: \rho(\mathbf{x}, \mathbf{y}) \leq d\}|$
- 平均球サイズ  $V_d^{\text{ave}} := \frac{1}{|X|} \sum_{\mathbf{x} \in X} V_d(\mathbf{x})$

のとき, 最小距離  $d$  の符号  $C$  として,  $|C| \geq \frac{|X|}{V_{d-1}^{\text{ave}}}$  が存在

Levenshtein (ISIT 2002). 任意の  $1 \leq t \leq n$  に対し, 以下を満たす  
最小 Levenshtein 距離  $d = 2(t + 1) = 2\delta n$  の符号  $C$  が存在.

$$|C| \geq \frac{q^{n+t}}{I_q(n-t, t)^2} \quad \text{つまり} \quad \text{符号化率 } R \geq 1 + \delta - 2H_q(\delta)$$

## グラフ理論による下界

集合  $X \subseteq \Sigma^n$  に対し, グラフ  $G = (V, E)$  を

- 各  $x \in X$  が頂点,  $d_L(x, y) \leq d - 1$  なら辺  $(x, y)$  が存在と定めると,
- $G$  の独立集合の最大サイズ  $= \alpha(G) \Leftrightarrow A_q(n, d) = \alpha(G)$

- 独立数 (independence number)  $\alpha(G)$  に関するグラフ理論の結果が利用できる
  - Turán の定理より GV 限界が導かれる (Tothluizen (1997))
  - Jiang, Vardy (IEEE IT 2004) による GV 限界の改良もこれ

# Caro-Wei 限界による下界

## Caro-Wei 限界

$$\alpha(G) \geq \sum_{x \in V} \frac{1}{1 + \deg(x)}$$

**Theorem 5.** 任意の  $d = 2(t + 1) < n$ , 整数  $1 \leq r \leq n$  に対し,

$$A_q(n, d) \geq \left\lfloor \frac{\left( q^n - \sum_{i=r}^n \binom{n-1}{i-1} q (q-1)^{i-1} \right)^2}{I_q(n-t, t) \left( q^{n-t} \cdot I_q(n, t) - \sum_{i=r}^n \binom{n-1}{i-1} q (q-1)^{i-1} \cdot \left( \sum_{j=1}^t \binom{i-t}{j} \right) \right)} \right\rfloor$$

証明：集合  $X \subseteq \Sigma^n$  をラン数  $r$  以上の文字列集合とし、Caro-Wei 限界に  $\deg(x) \leq |L_{t,t}(x)| \leq |D_t(x)| \cdot I_q(n-t, t)$  を適用

## Sala, Gabrys, Dolecek (ISIT 2014) の下界式 (式自体は省略)

グラフの三角形数  $T$  を用いた以下を利用 ( $\Delta$  は最大次数)

$$\alpha(G) \geq \frac{|V|}{10\Delta} \left( \log \Delta - \frac{1}{2} \log \left( \frac{T}{|V|} \right) \right)$$

Jiang, Vardy (2004) は  $\frac{T}{|V|}$  の上界を与えて GV 限界を  $\log n$  倍改善

Sala, Gabrys, Dolecek (ISIT 2014) も漸近的に  $\log n$  倍改善??

However, the present work is focused on non-asymptotic bounds. To the best of the authors' knowledge, Theorem 1 is so far the strongest lower bound on deletion-correcting codes, with an improvement on the order of  $\log n$  over all existing bounds, in both the asymptotic and non-asymptotic cases.

と記載はあるが . . .

Alon, Bourla, Graham, He, Kravitz (IEEE IT 2023) が上記を使った改善

# 平均挿入・削除球サイズ上界の改良による下界

Levenshtein (ISIT 2002) は

$$|L_{t,t}(\mathbf{x})| \leq |D_t(\mathbf{x})| \cdot I_q(n-t, t)$$

から、以下を利用

$$V_d^{\text{ave}} := \frac{1}{|\Sigma^n|} \sum_{\mathbf{x} \in \Sigma^n} |L_{t,t}(\mathbf{x})| \leq \frac{I_q(n-t, t)}{q^n} \sum_{\mathbf{x} \in \Sigma^n} |D_t(\mathbf{x})| = \frac{I_q(n-t, t)^2}{q^t}$$

→ 挿入・削除球サイズ  $|L_{t,t}(\mathbf{x})|$  の上界の改良を目指す

## $|L_{t,t}(x)|$ の上界の改良

アイデア：数え上げの重複を考える

$D_t(00011110000111)$  において,

$x = 00\mathbf{0}111\mathbf{1}000\mathbf{0}111$  の黒い部分を削除したものを  $y$  とおく.

オレンジのペアの片方を一つずつ削除すると,  
その結果  $z$  は  $2^3 = 8$  通りあり, すべて  $y$  の部分文字列

→ 各  $|I_t(z)|$  において,  $|I_{t-3}(y)|$  は重複して数え上げられている

→  $7|I_{t-3}(y)|$  は数えなくてよい

## 主結果その2：平均挿入・削除球サイズ上界の改良による下界


ラン数  $r(x) \geq 2$  のときオレンジペアが1つ以上あることを利用

**Corollary 3.** 任意の  $1 \leq t \leq n$  に対し，以下を満たす最小距離  $d = 2(t + 1)$  の符号  $C$  が存在.

$$A_q(n, d) \geq \left\lfloor \frac{q^{n+t}}{I_q(n-t, t)^2 - (q^t - q^{-n+t+1})I_q(n-t+1, t-1)} \right\rfloor$$


符号化率は [Levenshtein\(2002\)](#) と同様で，  $R \geq 1 + \delta - 2H_q(\delta)$

# 符号化率と相対最小距離のトレードオフ： $q = 2$





# 符号化率と相対最小距離のトレードオフ： $q = 4$






# 数值計算結果：上界

$q$	$n$	$d$	[Lev02]	[KK13]	Theorem 1	Theorem 2
2	20	4	97 453	55 206	95 325	181 643
2	20	10	26 456	2 535	1 295	2 452
2	20	20	190 416	1 059	32	28
2	20	30	961 048	—	5	4
2	40	4	47 498 012 376	28 192 605 878	52 357 696 560	102 167 009 660
2	40	10	1 279 636 864	9 880 934	117 292 187	228 473 245
2	40	20	1 122 371 648	3 203 459	215 900	203 859
2	40	30	13 097 807 352	298 539	3 735	1 195
2	40	40	287 193 094 240	1 048 713	231	43
4	20	4	30 003 945 118	19 289 677 788	68 719 476 736	90 174 299 388
4	20	10	360 221 648	25 002 768	306 647 351	316 287 316
4	20	20	536 774 720	1 645 315	1 258 226	79 926
4	20	30	192 278 071 952	—	34 771	71
4	40	4	$\approx 14\,843 \times 10^{18}$	$\approx 10\,332 \times 10^{18}$	$\approx 38\,997 \times 10^{18}$	$\approx 51\,574 \times 10^{18}$
4	40	10	$\approx 6\,113 \times 10^{15}$	$\approx 461\,805 \times 10^{12}$	$\approx 27\,238 \times 10^{15}$	$\approx 36\,015 \times 10^{15}$
4	40	20	$\approx 133\,526 \times 10^{12}$	$\approx 158\,374 \times 10^9$	$\approx 7\,269 \times 10^{12}$	$\approx 2\,172 \times 10^{12}$
4	40	40	$\approx 34\,641 \times 10^{15}$	$\approx 2\,123 \times 10^9$	$\approx 173\,431 \times 10^6$	$\approx 69 \times 10^6$
4	40	60	$\approx 306\,026 \times 10^{18}$	—	164 423 496	108

# 数值計算結果：下界

$q$	$n$	$d$	[Lev02]	[SGD14]	Theorem 5	Corollary 3	$q$	$n$	$d$	[Lev02]	[SGD14]	Theorem 5	Corollary 3
2	10	4	16	2	18	17	4	10	4	4 364	842	4 489	4 382
2	10	6	1	0	1	1	4	10	6	88	14	78	88
2	10	8	0	0	0	0	4	10	8	4	0	3	4
2	10	10	0	0	0	0	4	10	10	0	0	0	0
2	10	12	0	0	0	0	4	10	12	0	0	0	0
2	10	14	—	—	—	—	4	10	14	—	—	—	—
2	10	16	—	—	—	—	4	10	16	—	—	—	—
2	10	18	—	—	—	—	4	10	18	—	—	—	—
2	10	20	—	—	—	—	4	10	20	—	—	—	—
2	20	4	4755	783	4968	4777	4	20	4	1 181 952 838	269 953 863	1 200 316 339	1 183 224 781
2	20	6	94	10	94	94	4	20	6	5 608 964	1 260 800	5 257 096	5 610 710
2	20	8	4	0	4	4	4	20	8	66 412	11 205	52 137	66 419
2	20	10	0	0	0	0	4	20	10	1 558	167	937	1 558
2	20	12	0	0	0	0	4	20	12	64	3	27	64
2	20	14	0	0	0	0	4	20	14	4	0	1	4
2	20	16	0	0	0	0	4	20	16	0	0	0	0
2	20	18	0	0	0	0	4	20	18	0	0	0	0
2	20	20	0	0	0	0	4	20	20	0	0	0	0
2	20	22	0	0	0	0	4	20	22	0	0	0	0
2	40	4	1 308 163 745	244 663 405	1 339 190 459	1 309 722 010	4	40	10	5 251 871 945 006	968 893 684 250	4 033 370 043 313	5 251 878 194 182
2	40	6	6 524 894	881 891	6 532 808	6 526 482	4	40	12	4 408 536 581	5 621 632 730	28 003 006 604	4 408 537 815
2	40	8	76 814	6 032	71 601	76 818	4	40	14	562 976 279	46 013 071	281 585 593	562 976 323
2	40	10	1 687	68	1 396	1 687	4	40	16	10 353 270	506 907	3 886 646	10 353 271
2	40	12	60	1	42	60	4	40	18	263 527	7 256	70 970	263 527
2	40	14	3	0	1	3	4	40	20	9 010	131	1 673	9 010
2	40	16	0	0	0	0	4	40	22	404	2	50	404
2	40	18	0	0	0	0							
2	40	20	0	0	0	0							
2	40	22	0	0	0	0							

# [KK13] との漸近的な比較



# まとめ

挿入・削除を訂正する最良符号のサイズの上界・下界を導出

- 球充填タイプの上界 (Theorem 1, Corollary 1)
- Elias タイプの上界 (Theorem 2, Corollary 2)
  - [HY20] のリスト復号可能性を利用
- [Lev02] を改良した下界 (Corollary 3)
  - 平均挿入・削除球サイズ上界の改良を利用
  - 漸近的には [Lev02] と等価

## 未解決問題

- エクスパンダーグラフの活用
- 下界の漸近的な改善（ランダム符号化は最適か??）

# 参考文献

- [2] B. Bukh, V. Guruswami, and J. Håstad. An improved bound on the fraction of correctable deletions. *IEEE Trans. Inf. Theory*, 63(1):93–103, 2017.
- [4] D. Cullina and N. Kiyavash. An improvement to Levenshtein’s upper bound on the cardinality of deletion correcting codes. *IEEE Trans. Inf. Theory*, 60(7):3862–3870, 2014.
- [5] V. Guruswami, X. He, and R. Li. The zero-rate threshold for adversarial bit-deletions is less than  $1/2$ . In *62nd IEEE Annual Symposium on Foundations of Computer Science, FOCS 2021, Denver, CO, USA, February 7-10, 2022*, pages 727–738. IEEE, 2021.
- [7] T. Hayashi and K. Yasunaga. On the list decodability of insertions and deletions. *IEEE Trans. Inf. Theory*, 66(9):5335–5343, 2020.
- [10] A. A. Kulkarni and N. Kiyavash. Nonasymptotic upper bounds for deletion correcting codes. *IEEE Trans. Inf. Theory*, 59(8):5115–5130, 2013.
- [11] V. I. Levenshtein. Binary codes capable of correcting deletions, insertions, and reversals. *Soviet Physics Doklady*, 10(8):707–710, 1966.
- [12] V. I. Levenshtein. Bounds for deletion/insertion correcting codes. In *Proceedings IEEE International Symposium on Information Theory*, page 370, 2002.
- [14] F. Sala, R. Gabrys, and L. Dolecek. Gilbert-varshamov-like lower bounds for deletion-correcting codes. In *2014 IEEE Information Theory Workshop, ITW 2014, Hobart, Tasmania, Australia, November 2-5, 2014*, pages 147–151. IEEE, 2014.