



中国科学技术大学

University of Science and Technology of China

伪随机理论及其运用 以最小哈希族的构造为例

部分结果已被 SODA 2026 接收 (Chen, Huang, and Li, 2026)

报告人：黄盛唐 (PB22000196)

指导老师：陈雪 特任教授

中国科学技术大学

2026 年 6 月 3 日



- ▶ **随机化**是计算机科学的核心方法之一：算法、密码学、概率方法 ...
- ▶ 真随机比特**昂贵且稀缺** $\implies$ **去随机化**：用尽量少的随机性模拟真随机的行为。

- ▶ **随机化**是计算机科学的核心方法之一：算法、密码学、概率方法 ...
- ▶ 真随机比特**昂贵且稀缺** $\implies$ **去随机化**：用尽量少的随机性模拟真随机的行为。

定义 – 伪随机生成器 (PRG)

$G: \{0, 1\}^\ell \rightarrow D$ 让任何 $f \in \mathcal{F}$ 都无法区分 $G(U_\ell)$ 与真随机的 $x \sim D$ (误差 ε)。 ℓ 称为 **种子长度**。

$$\forall f \in \mathcal{F}, \quad \mathbb{E}[f(G(U_\ell))] = \mathbb{E}_{x \sim D}[f(x)] \pm \varepsilon.$$

- ▶ **哈希函数族** $\iff$ **PRG**: 从 $\mathcal{H} = \{h: [M] \rightarrow [M]\}$ 中均匀采样 h , 等价于以 $\log |\mathcal{H}|$ 比特种子在 $[M]^N$ 中生成一个向量。
- ▶ 因此哈希族**规模的对数** = 种子长度 = 随机性使用, 是衡量构造质量的核心量。

定义 – [Broder, Charikar, Frieze, and Mitzenmacher, 1998]

$\mathcal{H} = \{h: [M] \rightarrow [M]\}$ 是误差为 δ 的**最小哈希族**, 若对任意 $X \subseteq [M]$ 与 $y \notin X$,

$$\Pr_{h \sim \mathcal{H}} \left[h(y) < \min_{x \in X} h(x) \right] = \frac{1 \pm \delta}{|X| + 1}.$$

将 y 推广为大小至多 k 的子集 Y ($X \cap Y = \emptyset$), 即得 k -**最小哈希族**.

定义 – [Broder, Charikar, Frieze, and Mitzenmacher, 1998]

$\mathcal{H} = \{h: [M] \rightarrow [M]\}$ 是误差为 δ 的**最小哈希族**, 若对任意 $X \subseteq [M]$ 与 $y \notin X$,

$$\Pr_{h \sim \mathcal{H}} \left[h(y) < \min_{x \in X} h(x) \right] = \frac{1 \pm \delta}{|X| + 1}.$$

将 y 推广为大小至多 k 的子集 Y ($X \cap Y = \emptyset$), 即得 k -**最小哈希族**.

广泛应用:

- ▶ 集合相似度估计、网页去重
- ▶ 流式 ℓ_0 采样、草图算法
- ▶ 图聚类、稀有度近似、数据挖掘

最经典应用: Jaccard 相似度

对集合 $A, B \subseteq [M]$,

$$\Pr_h \left[\min_{a \in A} h(a) = \min_{b \in B} h(b) \right] = (1 \pm \delta) \cdot \frac{|A \cap B|}{|A \cup B|}.$$

$\Rightarrow$ 天然要求**乘法误差**.

路线一：基于有限次独立性 (bounded independence)

- ▶ Indyk (2001): $t = O(\log 1/\delta)$ 次独立 $\Rightarrow$ 误差 δ 的最小哈希族;
- ▶ Pătraşcu and Thorup (2016): $t = \Omega(\log 1/\delta)$ 必要 $\Rightarrow$ 紧致;
- ▶ Feigenblat, Porat, and Shiftan (2011): 对 k -最小哈希给出 $O(\log 1/\delta + k \log \log 1/\delta)$ 次独立上界。

局限: (i) k -最小哈希所需独立次数上下界仍有 **gap**; (ii) t 次独立需 $\Theta(t \log NM)$ 比特, 当 $\delta = o(1)$ 时**无法达到最优种子长度** $O(\log(NM/\delta))$ 。

路线一：基于有限次独立性 (bounded independence)

- ▶ Indyk (2001): $t = O(\log 1/\delta)$ 次独立 $\Rightarrow$ 误差 δ 的最小哈希族;
- ▶ Pătraşcu and Thorup (2016): $t = \Omega(\log 1/\delta)$ 必要 $\Rightarrow$ 紧致;
- ▶ Feigenblat, Porat, and Shifan (2011): 对 k -最小哈希给出 $O(\log 1/\delta + k \log \log 1/\delta)$ 次独立上界。

局限: (i) k -最小哈希所需独立次数上下界仍有 **gap**; (ii) t 次独立需 $\Theta(t \log NM)$ 比特, 当 $\delta = o(1)$ 时**无法达到最优种子长度** $O(\log(NM/\delta))$ 。

路线二：基于组合矩形 (combinatorial rectangles) 的 PRG

- ▶ Saks, Srinivasan, Zhou, and Zuckerman (1999): 归约到组合矩形 PRG, 得到 $O(\log^{3/2} NM)$ 种子长度, 多项式小的误差 ($1/\text{poly}(N)$);
- ▶ Gopalan and Yehudayoff (2020) (SOTA): $O(\log NM \cdot \log \log NM)$ 种子长度, 多项式小的误差。

局限: 最小哈希要求 $\delta/|X|$ 量级的乘法误差, 对应极小加法误差; 该路线**无法消除** $\log \log NM$ 因子。



定理 – 非形式化

基于有限次独立性的构造，要实现误差为 δ 的 k -最小哈希族，

$\Theta(k + \log 1/\delta)$ 次独立性是充分且必要的。

定理 – 非形式化

基于有限次独立性的构造, 要实现误差为 δ 的 k -最小哈希族,

$\Theta(k + \log 1/\delta)$ 次独立性是充分且必要的。

哈希族	所需独立次数	来源
最小哈希 ($k = 1$)	$\Theta(\log 1/\delta)$ (紧)	Ind01; PT16
k -最小哈希	$O(\log 1/\delta + k \log \log 1/\delta)$ (上界, 不紧)	FPS11
k -最小哈希	$\Theta(k + \log 1/\delta)$ (紧)	本文

定理 – 非形式化, 设 $M = \text{poly}(N)$

存在最小哈希族的显式构造, 种子长度为 $O(\log N)$ (最优), 乘法误差为 $2^{-O(\log N / \log \log N)}$ (亚常数, 几乎多项式小)。

定理 – 非形式化, 设 $M = \text{poly}(N)$

存在最小哈希族的显式构造, 种子长度为 $O(\log N)$ (最优), 乘法误差为 $2^{-O(\log N / \log \log N)}$ (亚常数, 几乎多项式小)。

方法	种子长度	误差	来源
有限次独立性	$\Theta(\log 1/\delta \cdot \log N)$	δ	Ind01; FPS11
组合矩形的 PRG	$O(\log N \cdot \log \log N)$	$1/\text{poly}(N)$	SSZZ99; GY20
非显式构造	$\Omega(\log(N/\delta))$	δ	—
本文	$O(\log N)$	$2^{-O(\log N / \log \log N)}$	—

- ▶ 首次在最优种子长度下, 将乘法误差压低至亚常数级别;
- ▶ 推广到 k -最小哈希: $k = \log^{O(1)} N$ 时, 种子长度 $O(k \log N)$, 误差量级不变。

感谢各位老师的聆听！

敬请批评指正。

- [BCFM98] Andrei Z. Broder, Moses Charikar, Alan M. Frieze, and Michael Mitzenmacher. Min-wise independent permutations. In *Proceedings of the thirtieth annual ACM symposium on Theory of Computing*, pages 327–336, 1998.
- [CHL26] Xue Chen, Shengtang Huang, and Xin Li. Explicit Min-wise Hash Families with Optimal Size. In *Proceedings of the 2026 Annual ACM-SIAM Symposium on Discrete Algorithms (SODA)*, pages 2512–2539. SIAM, 2026.
- [FPS11] Guy Feigenblat, Ely Porat, and Ariel Shiftan. Exponential time improvement for min-wise based algorithms. *Information and Computation*, 209(4):737–747, 2011.
- [GY20] Parikshit Gopalan and Amir Yehudayoff. Concentration for Limited Independence via Inequalities for the Elementary Symmetric Polynomials. *Theory of Computing*, 16:1–29, 2020.
- [Ind01] Piotr Indyk. A Small Approximately Min-Wise Independent Family of Hash Functions. *Journal of Algorithms*, 38(1):84–90, 2001.
- [PT16] Mihai Pătraşcu and Mikkel Thorup. On the k -Independence Required by Linear Probing and Minwise Independence. *ACM Transactions on Algorithms*, 12(1):8:1–8:27, 2016.
- [SSZZ99] Michael E. Saks, Aravind Srinivasan, Shiyu Zhou, and David Zuckerman. Low Discrepancy Sets Yield Approximate Min-Wise Independent Permutation Families. In *RANDOM/APPROX*, pages 11–15, 1999.