

随机指纹

用少量信息完成快速验证

随机算法部分的第一项主题

第一讲借助图割勾勒了课程的三条主线；从本讲开始，我们正式进入随机算法与随机化技术。贯穿全讲的做法是：不再完整搬运或比较一个庞大对象，而是随机选取一个很短的“指纹”。相同对象在任何随机选择下都得到相同指纹；不同对象虽可能碰撞，但碰撞概率可以严格控制。矩阵乘法检验、多项式恒等检验、通信复杂度、完美匹配、字符串匹配和流式算法，都将由这一条思路串联起来。

高级算法课程教学团队

南京大学

第二讲 · 随机算法与随机化技术

学习目标与阅读建议

完成本讲后，你应当能够：

1. 证明 Freivalds 矩阵乘法检验的单侧错误界，并进行独立重复放大；
2. 区分形式多项式与有限域上的多项式函数，完整证明 Schwartz-Zippel 定理；
3. 为相等性通信问题设计只需 $O(\log n)$ 位的随机协议；
4. 识别行列式、滚动余数和根多项式这三类代数指纹；
5. 在陈述结论时同时交代随机性的来源、错误方向、域大小以及计算模型。

第一次阅读可先掌握sections 1 and 2、定理 3.3 的证明、第 4 节中的多项式协议，再从完美匹配、Karp-Rabin 与多重集合三节中选择一节精读。随机模素数的两种算法是补充视角。附录只收录概率、素数计数、有限域和多项式代数等数学工具，所有高级算法都在正文中讲完。

除非另有说明，代数算法的时间按“域运算次数”计算；涉及通信、空间与字长 RAM 时，则会单独说明每个数需要多少位。通信和空间界中的对数以 2 为底。对正整数 n ，记 $[n] = \{1, \dots, n\}$ 。

Contents

学习目标与阅读建议	i
1 先丢掉信息，再保留判断能力	1
2 验证未必需要重算：Freivalds 算法	1
3 随机取值：多项式恒等检验的代数核心	2
4 少说几句话也能判断相等：通信复杂度	4
5 完美匹配：行列式提供随机见证	5
6 Karp-Rabin：用滚动指纹搜索字符串	6
7 多重集合：在数据流中比较相等性	7
8 设计随机指纹时应检查什么	8
9 习题	8
A 概率放大与素数计数工具	9
B 有限域与多项式代数工具	10
C 文献说明	11

1 先丢掉信息，再保留判断能力

设 X, Y 来自一个很大的对象空间 $\mathcal{U}$ 。随机指纹并不是无损压缩：从指纹通常无法恢复原对象。它只希望保留当前问题真正需要的信息——“两者是否相等”。形式化地说，随机种子 s 从一个指纹函数族中选出 $h_s: \mathcal{U} \rightarrow \mathcal{R}$ ，并满足：

- (i) 若 $X = Y$ ，则对每个 s 都有 $h_s(X) = h_s(Y)$ ；
- (ii) 若 $X \neq Y$ ，则 $\mathbb{P}_s[h_s(X) = h_s(Y)] \leq \varepsilon$ ；
- (iii) 种子、指纹和求值过程都远小于原对象的完整表示。

指纹值域小，就不可能对所有对象保持一一对应；碰撞不可避免。随机化的作用不是消灭碰撞，而是让事先固定的一对不同对象难以预知本次使用的碰撞方式。本文默认输入先固定、随机种子后抽取。若对手可以看到种子后再选择输入，就需要使用新的或保密的种子，并重新证明碰撞界。




图 1: 随机指纹把一次大对象比较变成两次求值和一次短值比较。证明的核心是数清楚哪些随机选择会造成碰撞。

对象或断言	随机指纹	碰撞为何稀少
AB 与 C	$(AB)r$ 与 Cr	非零矩阵的一行给出一个非平凡线性方程
多项式 f 与零多项式	$f(r_1, \dots, r_m)$	非零低次多项式在网格中的零点有限
二进制串 x, y	多项式取值或模素数余数	差多项式根少，差整数的素因子少
多重集合 A, B	$\prod_{a \in A} (r - a)$	元素重数变成根的重数

表 1: 每个应用都先找出“不相等”的代数见证，再估计随机选择隐藏该见证的概率。

先说清楚哪一边可能出错

比较两个对象时，相同对象绝不会被判成不同；不同对象却可能碰撞，所以只能“误报相等”。完美匹配一节的错误方向恰好反过来：没有完美匹配的图一定被拒绝，有完美匹配的图却可能在随机赋值后得到零行列式而被漏报。只写“以高概率正确”会掩盖算法最重要的结构。

2 验证未必需要重算：Freivalds 算法

给定 $A, B, C \in \mathbb{F}^{n \times n}$ ，任务是检查 $AB = C$ 。经典矩阵乘法需要 $O(n^3)$ 次域运算。Freivalds 的观察是：若两个矩阵相等，它们作用在任意向量上都应得到相同结果；为了发现一个错误等式，我们不必一次检查所有向量 [3]。

Freivalds(A, B, C)

1. 从 $\{0,1\}^n$ 中均匀选取随机向量 r ;
2. 依次计算 $u = Br$ 、 $v = Au$ 与 $w = Cr$;
3. 若 $v = w$ 则通过检验, 否则拒绝。

这里不能先算 AB 。按照括号 $A(Br)$ 计算, 只需三次稠密矩阵—向量乘法, 即 $O(n^2)$ 次域运算; 额外存储 $O(n)$ 个域元素, 并消耗 n 个随机比特。读取三个稠密矩阵本身已经需要 $\Theta(n^2)$ 个字。

定理 2.1 (Freivalds 算法的正确性)。 在任意域上, 若 $AB = C$, 算法以概率 1 通过; 若 $AB \neq C$, 错误通过的概率至多为 $1/2$ 。

证明。 若 $AB = C$, 则对每个 r 都有 $A(Br) = (AB)r = Cr$ 。

下面设 $M = AB - C \neq 0$ 。从 M 中选取一个非零元素 M_{ij} 。固定 r_j 之外的所有随机坐标后, 方程 $(Mr)_i = 0$ 化为

$$M_{ij}r_j = -\sum_{k \neq j} M_{ik}r_k.$$

由于 M_{ij} 在域中可逆, 该方程至多允许 r_j 取一个值。0 与 1 在任意域中都是不同元素, 因此均匀随机的 $r_j \in \{0,1\}$ 使命题成立的条件概率至多为 $1/2$ 。算法通过还要求整个向量 Mr 都为零, 概率不会更大。□

推论 2.2 (独立重复)。 用相互独立的随机向量执行 t 次, 并且只在每次都通过时接受。错误乘积被接受的概率至多为 2^{-t} , 代价是 $O(tn^2)$ 次域运算。若目标错误率为 δ , 取 $t = \lceil \log_2(1/\delta) \rceil$ 即可。

证明真正使用了什么

把每个坐标从有限集合 $S \subseteq \mathbb{F}$ 中独立均匀选取, 同样的固定坐标论证给出 $1/|S|$ 的错误界。关键不是矩阵的各行彼此独立, 而是固定其他坐标之后, 一个非零系数只允许当前坐标取很少的值。

精确域运算与浮点数不是一回事

上述单侧错误保证依赖精确等式。若使用浮点数和容差判断, 舍入误差会改变“通过”的含义, 定理不能原样照搬。对有理数运算, 若讨论位复杂度, 还必须估计分子和分母的增长, 而不能只数域运算次数。

3 随机取值: 多项式恒等检验的代数核心

Freivalds 算法检验的是线性映射是否相同。多项式恒等检验 (PIT) 把问题推广为:

$$\text{给定 } f \in \mathbb{F}[x_1, \dots, x_m], \quad f \equiv 0 \text{ 吗?}$$

符号 $f \equiv 0$ 表示所有形式系数都为零。它不等价于“在域中每个点都取零”。例如 $x^p - x$ 在 $\mathbb{F}_p[x]$ 中不是零多项式, 却在 $\mathbb{F}_p$ 的每个元素上取值为零。因此, 黑盒 PIT 的定理必须同时交代形式多项式、次数和可选取的域元素数目。

我们假设可以高效计算 f 在指定点的值。它可能由算术电路、行列式或乘积公式给出；把它完全展开成单项式之和反而可能非常昂贵。多元多项式的总次数，是其非零单项式中指数之和的最大值。

例 3.1 (同一个多项式的紧凑表示)。 对 Vandermonde 矩阵 $V_{ij} = x_i^{j-1}$ ，有

$$\det V = \prod_{1 \leq j < i \leq m} (x_i - x_j).$$

行列式和乘积式都能直接求值；若按行列式定义完全展开，却要遍历 $m!$ 个排列。黑盒 PIT 只计算给定表示在随机点的值，不要求先写出全部系数。

3.1 一元多项式的根数界

引理 3.2 (根数界)。 域 $\mathbb{F}$ 上次数为 d 的非零一元多项式，至多有 d 个不同的根。

证明。 对 d 归纳。非零常数没有根。若正次数多项式 f 以 a 为根，因式定理给出 $f(x) = (x - a)g(x)$ ，且 $\deg g = d - 1$ 。 f 的其他根都必须是 g 的根，因此总数至多为 $1 + (d - 1) = d$ 。□

这是一条对任意域都成立的代数事实，并不是关于复数分解的“代数基本定理”。于是，对有限集合 $S \subseteq \mathbb{F}$ 中均匀随机的 r ，

$$f \neq 0 \implies \mathbb{P}[f(r) = 0] \leq \frac{d}{|S|}.$$

当 $|S| \leq d$ 时，这个上界仍然正确，却没有信息量。根数界也给出一个确定性基准：若域中至少有 $d + 1$ 个不同元素，则次数至多为 d 的多项式恒等为零，当且仅当它在任意 $d + 1$ 个不同点上都取零。随机算法把这 $d + 1$ 次求值换成一次较大集合中的随机求值，并承担可控的错误概率。

3.2 Schwartz-Zippel 定理

多元版本源于 DeMillo-Lipton、Schwartz 与 Zippel 的工作 [1, 6, 8]。

定理 3.3 (Schwartz-Zippel)。 设 $f \in \mathbb{F}[x_1, \dots, x_m]$ 是总次数至多为 d 的非零多项式。 $S \subseteq \mathbb{F}$ 有限， $r_1, \dots, r_m$ 从 S 中相互独立且均匀选取，则

$$\mathbb{P}[f(r_1, \dots, r_m) = 0] \leq \frac{d}{|S|}.$$

等价地， f 在网格 S^m 中至多有 $d|S|^{m-1}$ 个零点。

证明。 对变量个数 m 归纳。 $m = 1$ 时结论就是引理 3.2。当 $m > 1$ 时，把 f 看成关于最后一个变量的多项式：

$$f(x_1, \dots, x_m) = \sum_{i=0}^k x_m^i f_i(x_1, \dots, x_{m-1}), \quad f_k \neq 0.$$

因为 f 的总次数至多为 d ，所以 $\deg f_k \leq d - k$ 。记事件 $E = \{f_k(r_1, \dots, r_{m-1}) = 0\}$ 。归纳假设给出

$$\mathbb{P}(E) \leq \frac{d - k}{|S|}.$$

若 E 不发生, 前 $m-1$ 个变量代入后, 剩下的是关于 x_m 的一个非零 k 次多项式。由于 r_m 在条件化后仍然均匀分布于 S , 根数界给出

$$\mathbb{P}[f(r_1, \dots, r_m) = 0 \mid E^c] \leq \frac{k}{|S|}.$$

无需估计 E 发生后会怎样, 直接把“最高次系数消失”和“剩余一元多项式取零”两种可能合并:

$$\mathbb{P}[f(r) = 0] \leq \mathbb{P}(E) + \mathbb{P}[f(r) = 0 \mid E^c] \leq \frac{d-k}{|S|} + \frac{k}{|S|} = \frac{d}{|S|}.$$

□

黑盒多项式恒等检验

给定次数至多为 d 的多项式 f 的求值方法, 以及有限集 $S \subseteq \mathbb{F}$:

1. 独立均匀选取 $r_1, \dots, r_m \in S$;
2. 若 $f(r_1, \dots, r_m) = 0$, 则回答“恒等为零”, 否则回答“不恒为零”。

零多项式永远通过; 非零多项式被误判为零的概率至多为 $d/|S|$ 。一次运行的时间是一次求值所需的时间, 不能仅凭次数界推出。

三个容易被省略的条件

Schwartz-Zippel 从一个**非零形式多项式**出发, 使用它的**总次数**, 并要求各坐标**独立抽样**。若基础域太小, 可以在允许的计算模型中转到扩域; 仅对一个小域中的所有点求值, 未必能区分非零形式多项式与零函数。

4 少说几句话也能判断相等: 通信复杂度

Alice 持有 $x \in \{0,1\}^n$, Bob 持有 $y \in \{0,1\}^n$ 。双方只通过通信共同计算

$$\text{EQ}(x, y) = \begin{cases} 1, & x = y, \\ 0, & x \neq y. \end{cases}$$

通信复杂度模型由 Yao 提出[7]; 局部计算不计代价, 只统计双方交换的比特数。

先看单向确定性协议: 若 Bob 发出的消息少于 n 位, 消息种类少于 2^n , 必有两个不同字符串 y, y' 产生同一条消息。Alice 在输入 $x = y$ 时必须接受这条消息, 于是面对不相等的输入对 (y, y') 也会接受。发送完整字符串需要 n 位, 所以单向确定性通信复杂度恰为 n 。

即使允许双方交互, 精确确定性下界仍为 n 。确定性协议的每条完整通信记录都对应一个输入矩形 $A \times B$ 。一个接受矩形不可能同时包含两个不同的对角输入 (x, x) 与 (y, y) , 否则矩形性质还会把不相等的 (x, y) 包含进来。于是 2^n 个对角输入需要至少 2^n 条接受记录; 最坏通信量为 c 的协议至多有 2^c 条记录, 所以 $c \geq n$ 。这里约定由一位指定参与者输出答案。

4.1 多项式指纹协议

双方事先固定一个满足 $n^2 < p < 2n^2$ 的素数 p ; $n \geq 2$ 时 Bertrand 定理 保证它存在。将字符串编码成

$$f_x(z) = \sum_{i=0}^{n-1} x_{i+1} z^i \in \mathbb{F}_p[z].$$




图 2: 单向私有随机协议: 随机点由 Bob 选择, 因此需要连同指纹值一起发送。

Bob 从 $\mathbb{F}_p$ 中均匀选择 r , 发送 $(r, f_y(r))$ 。Alice 计算 $f_x(r)$ 并比较。若 $x = y$, 每个随机点都通过。若 $x \neq y$, 差多项式 $h = f_x - f_y$ 至少有一个系数为 1 或 -1 , 因此在 $\mathbb{F}_p$ 中仍非零, 且次数至多为 $n - 1$ 。由根数界,

$$\mathbb{P}[f_x(r) = f_y(r)] \leq \frac{n-1}{p} < \frac{1}{n}.$$

随机点和取值各占 $\lceil \log p \rceil$ 位, 总通信量为 $O(\log n)$ 。这不是把对方输入“压缩后发来”, 而是只传递完成相等性判断所需的随机证据。

注 4.1 (公开随机性与私有随机性)。 若双方共享随机点 r , Bob 只需发送 $f_y(r)$; 上面的协议由 Bob 私下选择 r , 因此必须把 r 也发给 Alice。两种模型的通信量在渐近意义下相同, 但协议描述不能混用。

4.2 随机模素数校验

另一种办法把字符串直接看作 $[0, 2^n)$ 中的整数。令 $K = n^3$, Bob 从所有不超过 K 的素数中均匀选择 p , 发送 $(p, y \bmod p)$; Alice 与自己的余数比较。

若 $x \neq y$, 令 $z = |x - y|$ 。碰撞恰好意味着 $p \mid z$ 。由于 $0 < z < 2^n$, z 的不同素因子少于 n 个。记 $\pi(K)$ 为不超过 K 的素数数目, 由 $\pi(K) = \Theta(K / \log K)$,

$$\mathbb{P}[x \equiv y \pmod{p}] \leq \frac{n}{\pi(n^3)} = O\left(\frac{\log n}{n^2}\right) = O(1/n).$$

消息仍然只有 $O(\log n)$ 位。注意“随机选取不超过 K 的素数”不等于从 $\{0, 1, \dots, K\}$ 中随便选一个整数; 均匀素数采样与素性检验也是本地计算的一部分, 不能凭空视为一次常数时间操作。

5 完美匹配: 行列式提供随机见证

设二分图 $G = (L, R, E)$ 的两侧分别为 $L = \{\ell_1, \dots, \ell_n\}$ 与 $R = \{r_1, \dots, r_n\}$ 。给每条边一个独立不定元, 构造 Edmonds 矩阵[2]:

$$M_G(i, j) = \begin{cases} x_{ij}, & (\ell_i, r_j) \in E, \\ 0, & (\ell_i, r_j) \notin E. \end{cases}$$

定理 5.1 (Edmonds 行列式判据)。 G 存在完美匹配, 当且仅当形式多项式 $\det M_G$ 不恒为零。

证明。 按排列展开行列式:

$$\det M_G = \sum_{\sigma \in S_n} \text{sgn}(\sigma) \prod_{i=1}^n M_G(i, \sigma(i)).$$

其中 S_n 表示 $[n]$ 上的所有排列。排列 σ 对应的乘积非零，当且仅当边 $\{(\ell_i, r_{\sigma(i)}) : i \in [n]\}$ 构成完美匹配。不同排列选出的边变量集合不同，因而产生不同单项式；即使符号相反也不会抵消。所以展开式中存在非零项，恰好等价于图中存在完美匹配。□

现在选取有限域 $\mathbb{F}_q$ ，把每条边的不定元独立地赋为均匀随机域元素，再对所得数值矩阵做高斯消元。

定理 5.2 (随机完美匹配检测)。 算法使用 $O(n^3)$ 次域运算。若图没有完美匹配，它必定回答“不存在”；若图有完美匹配，它错误回答“不存在”的概率至多为 n/q 。

证明。 无完美匹配时，定理 5.1 说明行列式是零多项式，任何赋值都得到零。有完美匹配时，行列式是总次数为 n 的非零多项式。Schwartz-Zippel 定理把随机赋值后恰好取零的概率界为 n/q ；数值行列式可用 $O(n^3)$ 次域运算计算。□

取 $n^2 < q < 2n^2$ 的素数即可把错误率降到 $1/n$ 以下，并使域元素只需 $O(\log n)$ 位。这里的价值不在于宣称它优于所有确定性二分图匹配算法，而在于展示一种可复用的转化：组合对象的存在性先编码成形式多项式是否为零，再交给随机恒等检验。一次数值行列式只负责判断存在性，并不会直接输出匹配。

6 Karp-Rabin：用滚动指纹搜索字符串

给定文本串 $x = x_1 \cdots x_n \in \{0,1\}^n$ 和模式串 $y = y_1 \cdots y_m \in \{0,1\}^m$ ，其中 $m \leq n$ 。逐位置完整比较需要 $O(nm)$ 时间。相邻窗口共享 $m-1$ 个字符，Karp-Rabin 算法利用这部分重叠，只维护窗口代表整数的模素数余数[4]。

对长度为 m 的二进制串 $w = w_1 \cdots w_m$ ，定义

$$[w]_2 = \sum_{j=1}^m w_j 2^{m-j}.$$

第 i 个窗口记作 $X_i = x_i \cdots x_{i+m-1}$ 。从不超过 $K = mn^3$ 的素数中均匀选择 p ，令 $H_p(w) = [w]_2 \bmod p$ 。

Karp-Rabin 的 Monte Carlo 版本

1. 计算 $H_p(y)$ 、 $H_p(X_1)$ 以及 $a = 2^{m-1} \bmod p$;
2. 对 $i = 1, \dots, n - m + 1$:
 - (a) 若 $H_p(X_i) = H_p(y)$ ，报告位置 i ;
 - (b) 若还有下一个窗口，使用

$$H_p(X_{i+1}) \equiv 2(H_p(X_i) - x_i a) + x_{i+m} \pmod{p}$$

更新指纹。

更新式依次完成三件事：减去最高位、整体左移一位、接入新字符。算法始终只保存模 p 余数，并不会存下可能有 m 位的窗口整数。

若 $X_i \neq y$, 非零差值 $||X_i|_2 - |y|_2|$ 小于 2^m , 因而不同素因子少于 m 个。于是单个错误窗口发生指纹碰撞的概率满足

$$\mathbb{P}[H_p(X_i) = H_p(y)] \leq \frac{m}{\pi(mn^3)} = O\left(\frac{\log n}{n^3}\right).$$

对不超过 n 个窗口使用并合界, 整次运行出现任何伪命中的概率为

$$O\left(\frac{\log n}{n^2}\right) = o(1/n).$$

真正匹配一定具有相同指纹, 因此判定版本不会漏掉模式; 未经核验的报告位置则有上述小概率是错误的。也可以在每次指纹相等时逐字符复核, 从而得到永不出错的版本, 但其最坏时间会受候选位置数量影响。

因为 $p \leq mn^3 \leq n^4$, 所有算术量都只有 $O(\log n)$ 位。随机素数选定后, 预处理需 $O(m)$ 次字操作, 窗口扫描需 $O(n)$ 次字操作; 这里采用字长至少为 $\Theta(\log n)$ 、模运算视为常数时间的字长 RAM 模型。若按位操作计费, 还要加入模运算和素数生成的代价。若文本只能顺序到达, 为了知道离开窗口的字符, 还需要保存一个长度为 m 的循环缓冲区。

7 多重集合：在数据流中比较相等性

设 $A = \{a_1, \dots, a_n\}$ 、 $B = \{b_1, \dots, b_n\}$ 是定义在 $[n]$ 上的两个多重集合。排序可以比较它们, 却要保存输入; 完整频数表需要 $\Theta(n)$ 个计数器, 最坏为 $\Theta(n \log n)$ 位。即使只做互异性检验, 也要一个 n 位的出现标记向量。Lipton 提出的乘积指纹对元素顺序天然不敏感[5]。

把每个元素写成一个根:

$$f_A(z) = \prod_{i=1}^n (z - a_i), \quad f_B(z) = \prod_{i=1}^n (z - b_i).$$

只要域中 $1, \dots, n$ 互不相同, 多项式的唯一因子分解就说明: $f_A \equiv f_B$ 当且仅当 $A = B$ 。一个元素在多重集合中的重数, 正好是对应线性因子的重数。

7.1 有界值域下的简洁算法

固定满足 $n^2 < p < 2n^2$ 的素数 p , 从 $\mathbb{F}_p$ 中均匀选择 r , 并计算

$$\text{FING}_r(A) = \prod_{i=1}^n (r - a_i) \pmod{p}, \quad \text{FING}_r(B) = \prod_{i=1}^n (r - b_i) \pmod{p}.$$

定理 7.1 (流式多重集合相等性检验)。若 $A = B$, 两个指纹对每个 r 都相等; 若 $A \neq B$, 则

$$\mathbb{P}_r[\text{FING}_r(A) = \text{FING}_r(B)] \leq \frac{n-1}{p} < \frac{1}{n}.$$

算法只需一遍读入、 $O(n)$ 次模运算和 $O(\log n)$ 位工作空间。

证明. $p > n$ 保证 $[n]$ 中不同整数在 $\mathbb{F}_p$ 中仍然不同。若 $A \neq B$, 两个首一根多项式在 $\mathbb{F}_p[z]$ 中也不同; 最高次项相消后, $h = f_A - f_B$ 是次数至多为 $n-1$ 的非零多项式。根数界给出碰撞概率。处理数据流时只保留 p, r 、计数器和当前乘积, 每个量都只有 $O(\log n)$ 位。□

若输入为 $a_1, \dots, a_n \in [n]$, 要检查它们是否恰好组成一个排列, 只需把输入指纹与 $\prod_{i=1}^n (r - i) \pmod{p}$ 比较。于是互异性检验也能在线性时间、对数工作空间内完成, 且只能把非排列误判成排列。

7.2 什么时候还要随机化模数

在值域就是 $[n]$ 时，只要固定 $p > n$ ，不同元素就不会在模 p 后合并；原始材料中的“随机素数”并非必要。不过，当记录是很大的整数而我们仍希望使用短模数时，随机化 p 有其作用，同时也引入了两层不同的失败事件。

先把 $f_A - f_B$ 看作 $\mathbb{Z}[z]$ 中的非零多项式。从 $[L, 2L]$ 内的素数中均匀选择 p ，把系数模 p 化简，再从 $\mathbb{F}_p$ 中均匀选择 r ：

- (1) **模数不佳**：所有系数差都被 p 整除，非零整数多项式退化为 $\mathbb{F}_p[z]$ 中的零多项式；
- (2) **取值碰撞**：模 p 后多项式仍非零，但随机点 r 恰好是它的根。

回到 $a_i, b_i \in [n]$ 的参数，每个根多项式的系数绝对值至多为 $(n+1)^n$ ，因此可以固定一个满足 $0 < |c| \leq 2(n+1)^n$ 的非零系数差。若第一种坏事件发生，则 $p \mid c$ ；这样的不同素数只有 $O(n \log n)$ 个。另一方面，区间 $[L, 2L]$ 中有 $\Theta(L / \log L)$ 个素数。条件在第一种事件不发生时，根数界把第二种事件的概率限制在 n/L 。取 $L = \Theta((n \log n)^2)$ ，得到

$$\mathbb{P}[\text{指纹碰撞}] \leq \mathbb{P}[\text{模数不佳}] + \mathbb{P}[\text{取值碰撞} \mid \text{模数良好}] = O(1/n).$$

Schwartz-Zippel 只能在确认模 p 后仍是非零多项式之后使用；把两层随机性混在同一个“根的概率”里，会漏掉关键的可靠性条件。

8 设计随机指纹时应检查什么

六项检查表

1. **不相等的见证是什么**？非零矩阵行、非零多项式、非零整数差，或发生变化的根重数。
2. **随机性在哪里**？随机坐标、求值点、素数模数，还是两者兼有；哪些选择彼此独立？
3. **哪些坏选择会隐藏见证**？数的是线性方程的解、根，还是素因子？
4. **哪一边绝不出错**？明确写出可能误报相等，还是可能漏报存在性。
5. **指纹有多短**？扩大域会降低错误率，也会增加消息、存储和位运算成本。
6. **时间界属于哪个模型**？域运算、机器字运算、位运算和流式遍数不能互相替代。

9 习题

1. **扩大采样集合**。证明 Freivalds 算法从 S^n 中均匀选取向量时，错误通过概率至多为 $1/|S|$ 。若各坐标不独立，证明的哪一步需要修改？
2. **长方形矩阵**。对 $A \in \mathbb{F}^{a \times b}$ 、 $B \in \mathbb{F}^{b \times c}$ 、 $C \in \mathbb{F}^{a \times c}$ 设计相应检验，并给出域运算次数和随机比特数。
3. **紧例**。构造一组 $AB \neq C$ 的矩阵，使 Freivalds 算法恰以 $1/2$ 的概率错误通过。
4. **分别控制各变量次数**。若 f 关于 x_i 的次数至多为 d_i ，证明碰撞概率至多为 $\sum_i d_i / |S|$ ，并与总次数版本比较。

应用	一次运行代价	单侧错误	典型参数
Freivalds	$O(n^2)$ 次域运算	错误等式通过, 概率 $\leq 1/2$	独立重复 t 次
次数 d 的 PIT	一次多项式求值	非零多项式被判为零, 概率 $\leq d/ S $	$ S \gg d$
相等性通信	$O(\log n)$ 位	误报相等, 概率 $< 1/n$	$p \asymp n^2$
完美匹配	$O(n^3)$ 次域运算	漏报存在, 概率 $\leq n/q$	$q \asymp n^2$
Karp-Rabin	$O(n + m)$ 次字操作	报告错误位置, 概率 $o(1/n)$	随机 $p \leq mn^3$
多重集合数据流	$O(n)$ 次字操作, $O(\log n)$ 位	误报相等, 概率 $< 1/n$	固定 $p \asymp n^2$

表 2: 本讲算法的定量保证。表中的渐近参数省略了无关常数和有限个小规模输入。

5. **小有限域。**验证 $x^p - x$ 在 $\mathbb{F}_p[x]$ 中非零, 却在每个 $\mathbb{F}_p$ 元素上取零。说明为什么转到大小超过 p 的扩域后可能发现它非零。
6. **通信参数。**选择 p , 使多项式指纹协议的错误率至多为 2^{-40} ; 进一步把通信量写成 n 与一般目标错误率 δ 的函数。
7. **公开随机点。**若 Alice 与 Bob 共享随机 r , 重新计算协议的通信量。消息中少了哪些比特? 概率空间中仍有哪些随机变量?
8. **特征为二。**在特征为 2 的域上, 行列式展开中的正负号消失。证明二分图完美匹配的 Edmonds 判据仍然成立。
9. **核验候选位置。**在 Karp-Rabin 中逐字符核验每个指纹命中。估计期望运行时间, 并给出一个有大量真实匹配的位置的输入。
10. **插入—删除数据流。**数据流用 (a, Δ) 修改整数重数。尝试用 $\prod_a (r - a)^\Delta$ 构造指纹; 当 $\Delta < 0$ 时, 需要排除什么事件?
11. **重用随机点。**两次多重集合比较共用同一个 r 。并合界是否仍可用? 两次碰撞事件是否一定独立? 分别给出理由。
12. **审计一句话。**某讲义写道: “ $\mathbb{F}_p$ 上次数为 d 的非零多项式, 在随机点非零的概率至少为 $1 - d/p$ 。”列出要让这句话正确且有信息量所需的全部限定条件。

A 概率放大与素数计数工具

A.1 条件概率与独立性

当 $\mathbb{P}(B) > 0$ 时, 条件概率定义为 $\mathbb{P}(A | B) = \mathbb{P}(A \cap B) / \mathbb{P}(B)$ 。按事件 B 是否发生分解, 得到全概率公式

$$\mathbb{P}(A) = \mathbb{P}(A | B)\mathbb{P}(B) + \mathbb{P}(A | B^c)\mathbb{P}(B^c).$$

随机变量独立, 意味着知道其中一部分的取值不会改变其余变量的分布。Schwartz-Zippel 的证明正是在固定 $r_1, \dots, r_{m-1}$ 后, 继续使用 r_m 在 S 中均匀这一事实。

A.2 并合界与独立重复

任意事件 $E_1, \dots, E_k$ 都满足

$$\mathbb{P}\left[\bigcup_{i=1}^k E_i\right] \leq \sum_{i=1}^k \mathbb{P}(E_i).$$

并合界不要求事件独立。因此 Karp-Rabin 可以让所有窗口共用同一个随机素数；即使各窗口的碰撞事件相关，概率之和仍是合法上界。

若每次试验独立，且单次失败概率至多为 ε ，连续 t 次都失败的概率至多为 ε^t 。更一般地，若单次成功概率至少为 q ，则

$$\mathbb{P}[t \text{ 次都不成功}] \leq (1 - q)^t \leq e^{-qt}.$$

重复使用同一个随机样本不会产生上述概率放大。

A.3 一个整数能有多少不同素因子

若非零整数 z 有 k 个不同素因子，它们的乘积至少为 2^k ，所以

$$\omega(z) \leq \log_2 |z|.$$

这里 $\omega(z)$ 只数不同的素因子，不计重数。这条粗略上界已经足够分析随机模素数校验和 Karp-Rabin。

记 $\pi(N)$ 为不超过 N 的素数个数。素数定理给出

$$\pi(N) \sim \frac{N}{\ln N}.$$

本讲只使用其较弱推论：当 N 充分大时， $\pi(N) = \Theta(N/\log N)$ ，并且 $\pi(2N) - \pi(N) = \Theta(N/\log N)$ 。渐近算法可以把有限个小输入吸收到常数处理中。Bertrand 定理还保证每个整数 $N > 1$ 与 $2N$ 之间至少有一个素数；它只证明“存在”，不能替代随机素数分析所需的密度估计。

B 有限域与多项式代数工具

B.1 域、素域与扩域

域 $\mathbb{F}$ 上定义了加法与乘法，有加法和乘法单位元 $0, 1$ ；每个元素有加法逆元，每个非零元素有乘法逆元，并满足通常的结合、交换与分配律。整数模素数 p 构成素域

$$\mathbb{F}_p = \mathbb{Z}/p\mathbb{Z}.$$

模合数运算可能出现非零零因子，非零元素也未必可除，所以一旦证明需要域结构，就不能随意把素数模数换成合数。

每个有限域的大小都是 p^k ，其中 p 为素数、 $k \geq 1$ ；反过来，每个素数幂都对应一个有限域，并且在同构意义下唯一。若 $g \in \mathbb{F}_p[z]$ 是 k 次不可约多项式，则

$$\mathbb{F}_{p^k} \cong \mathbb{F}_p[z]/(g(z)).$$

扩域可以在保持特征不变的同时提供更多求值点，这正是基础域小于多项式次数时常用的补救办法。

B.2 多项式除法与因式定理

$\mathbb{F}[x]$ 中的多项式是形式有限和 $a_0 + a_1x + \cdots + a_dx^d$ 。对非零 g , 存在唯一的 $q, r \in \mathbb{F}[x]$ 使

$$f = qg + r, \quad r = 0 \text{ 或 } \deg r < \deg g.$$

令 $g = x - a$ 便得到因式定理: $f(a) = 0$ 当且仅当 $(x - a)$ 整除 f 。逐次提出线性因子, 就得到正文使用的一元多项式根数界。

非常数多项式若不能分解为两个更低次的非常数多项式之积, 就称为不可约。用不可约多项式取商, 正如用素数对整数取模, 所得商环才是域。

B.3 形式多项式不等于取值函数

$\mathbb{F}[x_1, \dots, x_m]$ 的元素首先是带系数的形式代数对象; 逐点求值后, 才得到 $\mathbb{F}^m \rightarrow \mathbb{F}$ 的函数。在无限域上, 不同形式多项式诱导不同函数; 在有限域上却未必如此。由 Fermat 小定理,

$$x^p - x = 0 \quad (\forall x \in \mathbb{F}_p),$$

但 $x^p - x$ 不是零多项式。Schwartz-Zippel 定理从“形式上非零”出发, 并把采样集合大小与次数比较, 正是为了避免把这两种概念混为一谈。

C 文献说明

Freivalds 的矩阵乘法检验见于 1977 年 IFIP 论文; 一些讲义把它写成 1979 年, 往往是与作者随后发表的相关论文混淆。多元根数界通常简称 Schwartz-Zippel 定理; DeMillo 与 Lipton 更早得到过紧密相关的结果, 因此也常见四人合称。本文的 Edmonds 矩阵是二分图的符号邻接矩阵, 不是一般图匹配中使用的斜对称 Tutte 矩阵。多重集合的乘积指纹由 Lipton 在 Princeton 技术报告 *Fingerprinting Sets* 中系统提出。

参考文献

- [1] R. A. DeMillo and R. J. Lipton. A probabilistic remark on algebraic program testing. *Information Processing Letters*, 7(4):193–195, 1978. doi:10.1016/0020-0190(78)90067-4.
- [2] J. Edmonds. Systems of distinct representatives and linear algebra. *Journal of Research of the National Bureau of Standards B*, 71B(4):241–245, 1967.
- [3] R. Freivalds. Probabilistic machines can use less running time. In *Information Processing 77*, pages 839–842. North-Holland, 1977.
- [4] R. M. Karp and M. O. Rabin. Efficient randomized pattern-matching algorithms. *IBM Journal of Research and Development*, 31(2):249–260, 1987. doi:10.1147/rd.312.0249.
- [5] R. J. Lipton. Fingerprinting sets. Technical Report CS-TR-212-89, Princeton University, 1989.
- [6] J. T. Schwartz. Fast probabilistic algorithms for verification of polynomial identities. *Journal of the ACM*, 27(4):701–717, 1980. doi:10.1145/322217.322225.
- [7] A. C.-C. Yao. Some complexity questions related to distributive computing. In *Proceedings of the 11th ACM Symposium on Theory of Computing*, pages 209–213, 1979. doi:10.1145/800135.804414.
- [8] R. Zippel. Probabilistic algorithms for sparse polynomials. In *EUROSAM 1979, Lecture Notes in Computer Science 72*, pages 216–226. Springer, 1979.