

ポラードの ρ 素因数分解法

ρ 法はポラード (Pollard) によって発明された素因数分解法であり、十桁程度の大きさまでの素因数を、確率的に探す乱択アルゴリズムである。

いま、合成数 N が与えられたとし、その素因数の 1 つを p とする。

$f(x)$ を多項式で表された関数とする。このとき、 a を $0 \leq a < p$ を満たす整数とし

$$x_0 = a, \quad x_{n+1} = \text{mod}(f(x_n), N)$$

で定義される数列 $\{x_n\}$ を考える。ただし、 $\text{mod}(x, N)$ は x を N で割った剰余を表すものとする。

さらに、 $y_n = \text{mod}(x_n, p)$ とする。

ここで、 $0 \leq y_n < p$ が成り立つから、数列 $\{y_n\}$ から連続した $p+1$ 個の項を取り出せば、鳩ノ巣原理により、少なくとも 1 組の等しい項が存在する。すなわち

$$y_J = y_I, \quad 1 \leq I < J \leq p+1$$

となる I, J が存在する。 $J - I = t$ ($t \leq p$) とおくと、

$$y_{I+t} = y_I$$

漸化式により y_n から y_{n+1} が一意的に決定されるから、 $n \geq I$ では、 t は数列 $\{y_n\}$ の周期となる。(ただし、 y_n から y_{n-1} は一意的に決定されるわけではないことに注意したい。)

数列 $\{y_n\}$ において、 $n \geq I$ における正で最小の周期を T で表し、これを単に周期と呼ぶことにする。

このとき、 $i \geq I$ である任意の i について

$$y_{i+T} - y_i = 0$$

したがって、

$$\text{mod}(x_{i+T} - x_i, p) = 0$$

これより、 $x_{i+T} - x_i$ は p の倍数であるから、 $x_{i+T} - x_i$ と N の最大公約数は p の倍数である。このとき、 $1, N$ 以外の最大公約数が見つければ、それは、 N の自明でない約数となる。

ここで、 $0 < (i+T) - i = T \leq p$ であるから

$$\text{mod}(x_j - x_i, p) = 0, \quad I \leq i < j \leq I + p$$

となる i, j が存在することになる。このとき、 $0 < j - i \leq p$ である。

いま、 $\text{mod}(x_j - x_i, p) = 0$ となる i, j が見つかったとしよう。このとき

$$\text{mod}(x_j, p) = \text{mod}(x_i, p)$$

$f(x)$ は x の多項式であるから、

$$\text{mod}(f(x_j), p) = \text{mod}(f(x_i), p)$$

よって $\text{mod}(f(x_j) - f(x_i), p) = 0$

すなわち

$$\text{mod}(x_{j+1} - x_{i+1}, p) = 0$$

これより

$$\text{mod}(x_j - x_i, p) = 0 \Rightarrow \text{mod}(x_{j+1} - x_{i+1}, p) = 0 \quad \dots \textcircled{1}$$

が成り立つ。

$I \leq i < j$ である場合を考える。このとき、数列 $\{y_n\}$ は循環の輪の中にあるから、 $\textcircled{1}$ を繰り返し用いると

$$\text{mod}(x_{j+1} - x_{i+1}, p) = 0 \Rightarrow \text{mod}(x_j - x_i, p) = 0$$

が得られる。よって

$$\text{mod}(x_j - x_i, p) = 0 \Leftrightarrow \text{mod}(x_{j+1} - x_{i+1}, p) = 0 \quad \dots \textcircled{2}$$

が成り立つ。

循環の輪の中では、 $\text{mod}(x_j - x_i, p) = 0$ となる i, j の組を見つけるのに、 $I \leq i < j \leq I + T - 1$ を満たす

全ての組について $|x_i - x_j|$ と N の最大公約数を求める必要はなく、 $\textcircled{2}$ により

$$j - i = 1, 2, 3, \dots, \left\lfloor \frac{T}{2} \right\rfloor$$

となる i, j の組のそれぞれ1ずつだけ $|x_i - x_j|$ と N の最大公約数を求めればよい。

したがって、 $I \leq i < j$ ならば、 i を I に固定するのが最も効率的である。しかし、 I を知ることができない。よって、ポラードは、 $|x_2 - x_1|$, $|x_4 - x_2|$, $|x_6 - x_3|$, \dots と N との最大公約数を求めた。ブレントは、このアルゴリズムを改良して、項数が2倍ごとに x_i を固定値とするアルゴリズムを考えた。さらに、ブレントのアルゴリズムを独自に改良することを考えた。ポラードの ρ 素因数分解法は、次にある上下に並んだ添字の項の差を用いる。下の行が空白の場合は用いない。添字の差は、1, 2, 3, \dots と連続する。

ポラードの元のアルゴリズムは、次の添字に従う。一度計算した項をすべて記憶することができないから、上の列と下の列を添字に持つ乱数列を同時に2本生成する。

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
	1		2		3		4		5		6		7		8		9		10		11		12		13		14		15	

ブレントによる改良アルゴリズムは、次の添字に従う。既に生成した項を1項だけ記憶することにより、乱数列を1本だけ生成して済みます。

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32
	1		2			4	4				8	8	8	8											16	16	16	16	16	16	16

ブレントの方法に独自の改良を加えたアルゴリズムは、既に生成した項を何項か記憶することにより、若干の高速化を図ったもので

4項だけ記憶する場合は

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
			4	4	4	4		5		6		7		8		10	10		12	12		14	14		16					

8項だけ記憶する場合は

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31
8 8 8 8 8 8 8 8 9 10 11 12 13 14 15

ところで、この最大公約数が N になった場合は、このアルゴリズムは失敗する。なぜなら、このとき $x_{2n} = x_n$ となるため、それ以降の数列がそれまでの繰り返しになってしまうからである。

註 数列 $\{y_n\}$ は、最初は周期的でなくても途中から周期的になる（循環の輪に入る）様子が、ギリシア文字の ρ に似ていることから、 ρ 法と呼ばれている。

以上の考察では、 $\text{mod}(x_j - x_i, p) = 0$ となる i, j の組を見つけるのに、 p のオーダーの回数の探索を行わなければならない。ところが、次の誕生日のパラドックスにより、 \sqrt{p} 程度のオーダーの回数の探索で見つけられる可能性がある。しかし、これは証明されたものではなく、実験結果から正しいのではないかと考えられている。

誕生日のパラドックス

23 人の人間が居れば、その中に同じ誕生日の 2 人(以上)がいる確率は約 $\frac{1}{2}$ である。これを、誕生日のパラドックスという。一般に、 n が十分大きいとき、 n 種類の値をとる真の乱数が \sqrt{n} 個あれば、乱数の中に同じ値を持つ 2 数(以上)が存在する確率は、 $\frac{1}{2}$ に近い。

したがって、数列 $\{y_n\}$ の項を \sqrt{p} 個集めたものが、もしも真の乱数を \sqrt{p} 個集めたものに近ければ、 \sqrt{p} 個の項の中に、 p を法として合同であるものが存在する確率は $\frac{1}{2}$ に近い。真の乱数については、その合同である 2 つの項の組を求めるのに、すべての 2 個の組み合わせである $\sqrt{p}C_2 \approx \frac{p}{2}$ 通りを調べなければならない。しかし、 $f(x)$ が多項式の場合は、性質①があるから、 \sqrt{p} 個程度の組み合わせを調べればよい。

誕生日のパラドックスの導出 (誕生日攻撃)

真の乱数が n 種類の値を取るとき、 k 個の乱数の中に同じ値を持つ 2 数(以上)が存在する確率を求めてみよう。

k 個の乱数がすべて異なる確率を p_1 とすると

$$p_1 = \frac{n P_k}{n^k} = \frac{n(n-1)(n-2)\cdots(n-k+1)}{n^k}$$

$$= \left(1 - \frac{0}{n}\right) \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \cdots \cdots \left(1 - \frac{k-1}{n}\right)$$

よって

$$\begin{aligned} \log p_1 &= \log\left(1 - \frac{0}{n}\right) + \log\left(1 - \frac{1}{n}\right) + \log\left(1 - \frac{2}{n}\right) + \cdots + \log\left(1 - \frac{k-1}{n}\right) \\ &= n \cdot \frac{1}{n} \left\{ \log\left(1 - \frac{0}{n}\right) + \log\left(1 - \frac{1}{n}\right) + \log\left(1 - \frac{2}{n}\right) + \cdots + \log\left(1 - \frac{k-1}{n}\right) \right\} \end{aligned}$$

n が十分大きく、 k もある程度の大きいときを考えると

$$\log p_1 \approx n \cdot \int_0^{\frac{k}{n}} \log(1-x) dx$$

x が十分に 0 に近いとき、 $\log(1-x) \approx -x$ であるから、 $\frac{k}{n}$ が十分に 0 に近いときを考えると

$$\log p_1 \approx n \cdot \int_0^{\frac{k}{n}} (-x) dx = n \cdot \left[-\frac{1}{2} x^2 \right]_0^{\frac{k}{n}} = -\frac{k^2}{2n}$$

よって

$$p_1 \approx e^{-\frac{k^2}{2n}}$$

したがって、 k 個の乱数の中に同じ値を持つ 2 数(以上)が存在する確率を p_2 とすると

$$p_2 = 1 - p_1 \approx 1 - e^{-\frac{k^2}{2n}}$$

これより、 n が十分大きい場合には

$$k \approx \sqrt{n} \text{ のとき } p_2 \approx 1 - e^{-\frac{1}{2}} \approx 0.39$$

$$k \approx 2\sqrt{n} \text{ のとき } p_2 \approx 1 - e^{-2} \approx 0.86$$

$$k \approx 3\sqrt{n} \text{ のとき } p_2 \approx 1 - e^{-\frac{9}{2}} \approx 0.99$$

$$k \approx 4\sqrt{n} \text{ のとき } p_2 \approx 1 - e^{-8} \approx 0.9997$$

となる。