

STRINGEK EGYENLŐSÉGÉNEK ELLENŐRZÉSE :

Legyen A és B két string:

A:

$$a_1, a_2, \dots, a_n \in \{0, 1\}^n$$
$$a = a_n 2^{n-1} + a_{n-1} 2^{n-2} + \dots + a_1$$

B:

$$b_1, b_2, \dots, b_n \in \{0, 1\}^n$$
$$b = b_n 2^{n-1} + b_{n-1} 2^{n-2} + \dots + b_1$$

a két sztring, akkor és csak akkor egyenlő, ha $a=b$, ehhez n bitet kell ellenőrizni, de kevesebb bitet szeretnénk küldeni ellenőrzésre.

Vegyünk egy p prímet! Legyen $Fp(a) = a \bmod p$ az ujjlenyomat. Ha $Fp(a) = Fp(b)$, akkor elfogadjuk az egyenlőséget. Viszont determinisztikusan választva a prímet $p < 2^n$ esetben : az ellenfél tud olyan példát adni, amikor hibázik az algoritmus. Az ötlet, hogy p legyen véletlenül generált prím (ilyet találni nehéz, de ezzel nem foglalkozunk). Tehát p -t véletlenül választjuk a τ -nál kisebb prímelek közül, ahol $\tau < 2^n$. Ekkor a kommunikáció: $O(\log \tau)$ -nyi bit. A hiba valószínűsége az $\Pr(Fp(a)=Fp(b) \mid a \neq b)$, ha ez kicsi, akkor jó az algoritmus. A prímszámtétel kimondja, hogy $\Pi(\tau) \cong \tau / \ln(\tau)$, ahol $\Pi(\tau) = a$ τ -nál kisebb prímelek száma. Az algoritmus során $\Pi(\tau)$ féle prímet választhatunk, és akkor van baj, ha a számok ugyanabba a maradékosztályba esnek, azaz p osztója $a-b$ abszolút értékének, legyen $c=|a-b|$.

Másrészt ha $c \leq 2^n$, akkor maximum n db prím osztója van. (Mivel ha x -nek több mint n db prím osztója van, akkor mind legalább 2, így $x \geq 2^n$.) Tehát legyen τ egy küszöbérték, ahol $\tau > n = \log c$. Ekkor a fentiek alapján $\Pr(Fp(a) = Fp(b) \mid a \neq b) \leq n / (\tau / \ln(\tau)) = (n / \tau) \ln(\tau)$ (mivel maximum n osztója lehet c -nek, és a véletlen prímet pedig $\tau / \ln(\tau)$ darab prím közül választhatjuk).

Ha $\tau = t n \ln(t n)$, valamely nagy t -re, akkor a fenti valószínűség $n / (t n \ln(t n)) \ln(t n \ln(t n)) \leq 2 / t (\approx O(1/t))$. Az átküldött bitek száma pedig $O(\ln(t) + \ln(n))$. Így ha $t = n$, akkor n bit helyett $\log(n)$ bit átküldése esetén a hiba valószínűsége legfeljebb $O(1/n)$.

MINTAILLESZTÉS

A mintaillesztés problémája a következő: adott két bináris sztring, S egy n bitből álló szöveg, amiben keresünk és egy M m db bitből álló mintát, amelynek az előfordulásait szeretnénk megtalálni. A feladat determinisztikus algoritmussal $O(m+n)$ időben megoldható (ld.: Algoritmusok II.). $O(mn)$ időben egy triviális kimerítő keresésen (brute force) alapuló algoritmus is megoldja. Itt is használhatjuk az ujjlenyomat technikát.

Legyen $S_j = s_j s_{j+1}, \dots, s_{j+m-1}$ a j -edik helyen kezdődő m hosszú részsstring, $1 \leq j \leq m-n+1$, legyen $F(S_j) = s_j * 2^{m-1} + s_{j+1} * 2^{m-2} + \dots + s_{j+m-1}$. Ekkor $S_j = M$ esetén $F(S_j) = F(M)$. Az algoritmus ezen értékeknek a fentiekben definiált ujjlenyomatát hasonlítja össze az $F(M)$ érték ujjlenyomatával.

Lényeges észrevétel, hogy $S_{j+1} = 2 [S_j - s_j 2^{m-1}] + s_{j+m}$, azaz a sorozat tagjai az előző tagból hatékonyan konstans időben számolhatóak, így a véletlenül generált prímre is $Fp(S_{j+1}) = 2 [Fp(S_j) - s_j * 2^{m-1}] + s_{j+m} \bmod p$. Tehát ujjlenyomatként az $Fp(Z) = Z \bmod p$ függvényt használjuk egy véletlenül generált p egy τ korlátnál nem nagyobb prímre. Ugyanúgy mint az első részben a sztringek összehasonlításánál kapjuk, hogy az algoritmus hibája legfeljebb $(n / \tau) \ln(\tau) = O((n \log \tau) / \tau)$ tehát kapunk egy Monte Carlo algoritmust. Legyen τ olyan, hogy a hiba $O(1/n)$ -re egyszerűsödjön.

A Monte Carlo algoritmus: Visszaadja az első j -t, amire $Fp(S_j) = Fp(M)$

Adódik, hogy a futásidő: $O(m+n)$.

$P(\text{hiba}) \leq 1/n$, hiba: ha mégsem egyezik valójában: $Fp(S_j) = Fp(M)$ de $S_j \neq M$

Las Vegas algoritmussá alakíthatjuk át a következőképpen:

1. MC futtatás $O(m+n)$ idő
2. valóban illeszkedik-e a minta (ellenőrzés) $O(m)$ idő
3. ha igen, akkor vége $O(1)$ idő
4. ha nem, akkor Brute Force

A 4. lépés a Brute Force algoritmus legfeljebb $1/n$ valószínűséggel hajtódik végre, a futási ideje $O(mn)$ így ezen lépés várható futási ideje is $O(m+n)$. Következésképpen a Las Vegas algoritmus futási ideje $O(m+n)$.

Összefoglalás

Összefoglalva, a következő 3 módszert használjuk ujjlenyomatok definiálására.

1. módszer: Legyen a kérdés, hogy $Q_1(x) = Q_2(x)$ igaz -e, ahol Q egy F test feletti polinom. A módszer egyenletes eloszlás alapján egy r kiértékelési hely választása, és $Q_1(r) = Q_2(r)$ tesztelése. Ez a sztring egyezésnél is használható. Legyen $Q_1 = a_1 x^{n-1} + a_2 x^{n-2} + \dots + a_1$ és $Q_2 = b_1 * x^{n-1} + b_2 * x^{n-2} + \dots + b_2$ a két sztring akkor és csak akkor egyezik meg, ha $Q_1(x) = Q_2(x)$.

2. módszer: A prímet választjuk véletlennek és adott x pontban értékelünk. A fenti példákban $x=2$ volt az érték ahol értékeltünk.

3. módszer: Ha a kérdés $a = b$, akkor megtehetjük azt is, hogy rögzítünk egy p prímet és egy véletlenül generált Q polinomra az F_p test felett vizsgáljuk, hogy $Q(a) = Q(b)$ teljesül -e.

INTERAKTÍV BIZONYÍTÁSI RENDSZEREK

Az interaktív bizonyítási rendszerben két játékos van.

1. Ellenőrző személy V , aki egy állításról szeretné eldönteni, hogy igaz vagy hamis. (Bonyolultságelméleti definíciókkal egy adott L nyelv esetén egy x szóról akarja eldönteni $x \in L$ teljesül-e.) Az ellenőrző polinomiális idejű véletlenített algoritmusokat használhat és kérdést tehet fel a bizonyítónak.
2. Bizonyító P , az ő esetében nincs időkorlát (mindent ki tud számolni). De lehet rosszindulatú bizonyító is, aki hazudhat (válaszra és a bizonyításra is) és V nem tudja leellenőrizni polinomiális időben ezt (mert pl exponenciális idejű a bizonyítás).

Def: Interaktív bizonyítási rendszer van egy eldöntendő L kérdésre, azaz a kérdés az IP bonyolultságelméleti osztályba tartozik (interaktív polinom idejű osztály, ha $\exists V$ ellenőrző és P bizonyító, úgy hogy ha:

- igaz a válasz ($x \in L$), akkor $\Pr(V(x,P) = \text{elfogad}) = 1$
- ha nem a válasz ($x \notin L$), akkor $\forall P'$ esetleg rosszindulatú bizonyítóra is: $\Pr(V(x,P') = \text{elfogad}) \leq \frac{1}{2}$.

GRÁFIZOMORFIZMUS

Def.: $G_1(V_1, E_1)$ izomorf $G_2(V_2, E_2)$ akkor és csak akkor, ha létezik egy π permutációja az $1, 2, \dots, |V|$ számoknak (csúcsok), hogy $(i, j) \in E_1$ akkor és csak akkor, ha $(\pi(i), \pi(j)) \in E_2$.

A gráfizomorfizmus problémája NP-ben van, ha izomorf a két gráf könnyű bizonyítást ellenőrizni (az adott permutációt kell csak ellenőrizni izomorfizmus -e.) A lenti ábrán két izomorf gráf van.

GRÁF NEM IZOMORFIZMUS

Válasz: igen, ha G_1 nem izomorf G_2 -vel.

Interaktív bizonyítási séma:

1. σ egy véletlen permutáció
2. $i \in \{1, 2\}$ véletlen értéket generálunk egyenletes eloszlás alapján
3. G_i gráfon σ permutációt végrehajtjuk, így kapjuk a H gráfot
4. H -t odaadjuk a bizonyítónak, és megkérdezzük, hogy G_1 -el vagy G_2 -vel izomorf.
5. Ha válaszként G_i -t kapjuk, akkor elfogadjuk, hogy G_1 és G_2 nem izomorf.



Állítás: Ez egy interaktív bizonyítási rendszer.

Bizonyítás:

- ha G_1 és G_2 nem izomorfak (tehát a válasz igen), akkor P meg tudja mondani melyiket választottuk, ezért a séma a választ elfogadja.
- ha G_1 és G_2 izomorfak (tehát a válasz hamis), akkor H alapján a bizonyító nem tudja eldönteni, melyik gráfot választottuk. Annyit tehet, hogy x valószínűséggel 1-et mond, és $1-x$ valószínűséggel 2-t mond. Viszont ebben az esetben a válasz elfogadásának valószínűsége

$$P(\text{elfogad}) = \frac{1}{2} x + \frac{1}{2} (1-x) = \frac{1}{2}$$

Példa izomorf gráfokra:



H3SAT PROBLÉMA

Def: 3CNF egy konjunktív normálforma, ahol minden tag 3 darab \vee jellel összekapcsolt esetleg negált változót tartalmaz, a formula a tagok konjunkciója. (példák 3CNF alakra: $(x \vee y \vee z) \wedge (a \vee b \vee c) \wedge \dots \wedge (e \vee f \vee g)$, $(x \vee !y \vee z) \wedge (y \vee z \vee c) \wedge \dots \wedge (e \vee f \vee g)$)

Def: 3SAT probléma: Adott 3CNF kielégíthető -e?

Def: H3SAT probléma: Adott 3CNF hányféleképpen elégíthető ki?

Tétel: Adott S érték esetén a $H3SAT = S$ probléma az IP osztályban van.

Bizonyítás: Elsőként aritmetizáljuk a formulát, ami egy gyakran használható technika. Rendeljük az x_i logikai változóhoz az $f(x_i) = 1 - x_i$ aritmetikai függvényt, a $!x_i$ logikai változóhoz az x_i aritmetikai függvényt. Továbbá a $c_i = l_{i1} \vee l_{i2} \vee l_{i3}$ logikai kifejezéshez az $f(c_i) = 1 - f(l_{i1})f(l_{i2})f(l_{i3})$ aritmetikai kifejezést. Például:

Az $x_1 \vee !x_2 \vee x_3$ logikai kifejezés aritmetizálása az $1 - (1 - x_1)x_2(1 - x_3)$ kifejezést adja. Könnyen látható, hogy egy c klóz akkor és csak akkor igaz, ha $f(c) = 1$. A teljes CNF aritmetizálását úgy kapjuk, hogy összeszorozzuk a benne szereplő klózok aritmetizáltjait. Például, ha $x = (x_1 \vee !x_2 \vee x_3) \wedge (!x_2 \vee x_3 \vee x_4)$, akkor

$$f(x) = (1 - (1 - x_1)x_2(1 - x_3))(1 - x_2(1 - x_3)(1 - x_4))$$

Könnyen belátható, hogy egy x 3CNF kifejezés akkor és csak akkor igaz, ha $f(x) = 1$.

Most legyen $Hf(x) = \sum_{x_1=0}^1 \sum_{x_2=0}^1 \dots \sum_{x_n=0}^1 f(x_1, \dots, x_n)$, ez az összeg pontosan a H3SAT probléma megoldását adja, mivel az összegben azon x_i értékek esetén kapunk 1-et, amelyek kielégítik a logikai formulát. Használjuk a következő jelöléseket $f_n(x_1, \dots, x_n) = f(x_1, \dots, x_i, x_{i+1}, \dots, x_n)$, azaz f_n egy n - változós függvény, a lerögzített változóknak megfelelő tag értéke a Hf összegből. Továbbá minden i -re definiáljuk a f_i i változós függvényt, amely az a részösszeg, ahol az első i darab változó van lerögzítve, ekkor ezen függvényekre teljesül, hogy $f_i(x_1, \dots, x_i) = f_{i+1}(x_1, \dots, x_i, 0) + f_i(x_1, \dots, x_i, 1)$. A fenti rekurziók alapján definiált f_0 konstans (0-változós függvény) pontosan a vizsgált $Hf(x)$ értéket adja vissza. Tehát az eldöntendő kérdés az, hogy $f_0 = S$ igaz -e.

A következő interaktív sémát használjuk:

Elsőként a bizonyítót megkérjük, hogy adja meg nekünk az f_1 egyváltozós függvényt (ennek a fokszáma legfeljebb $3n$). Ellenőrizzük, hogy a kapott g függvényre (nem tudhatjuk biztosan, hogy valóban f_1 -et kaptunk meg) $g(0) + g(1) = S$ teljesül -e. Ha nem, akkor a választ nem fogadjuk el, egyébként ellenőrizzük, hogy valóban az f_1 függvényt kaptuk-e meg. Ehhez legyen p egy prím, ami nagyobb, mint $3n$, és válasszunk egy r értéket a p feletti prímtestből véletlenszerűen. Vizsgáljuk meg, hogy $f_1(r) = g(r)$ teljesül -e, ha a válasz igen, akkor elfogadjuk a bizonyítást egyébként nem. A korábbiakhoz (előző óra) hasonlóan kapjuk a hiba valószínűségére, hogy $\Pr(\text{hiba}) = \Pr(\text{nem ugyanazt a függvényt adja vissza, de ugyanazt a kiértékelést kapjuk}) \leq 3m / p$.

Az egyetlen megmaradt probléma az, hogy mi nem tudjuk $f_1(r)$ pontos értékét. Ennek meghatározásához vegyük észre, hogy $f_1(r) = \sum_{x_2=0}^1 \dots \sum_{x_n=0}^1 f(r, x_2, \dots, x_n)$, tehát annak eldöntése, hogy $f_1(r) = g(r)$ teljesül -e, pontosan ugyanolyan feladat mint az eredeti feladatunk, csak egy változóval kevesebb van, így a sémát rekurzívan újra felhasználva ezt az egyenlőséget is ellenőrizhetjük.

Mivel összesen n db kérdés-felelet van, a teljes hiba valószínűségére azt kapjuk, hogy

$P(\text{hiba}) = P(g(r) = f_1(r) \mid g(z) \neq f_1(z)) \leq n * 3m / p \leq 1/2$, ha p értékét elegendően nagyra választjuk.

VISSZAFELE ELEMZÉS

Vegyük a következő rendező algoritmust. Vegyük a számok egy véletlen sorrendjét (ha determinisztikus algoritmusként tekintjük, akkor az átlagos futási időre kapunk ugyanilyen korlátot). Utána használjuk a beszűrő rendezés egy olyan változatát, ahol minden még be nem szűrt elemre egy kétirányú mutató számon tartja, hogy a már rendezett számok közé hova kell beszűrni.

Például, ha a kezdeti sorrend 1 7 5 4 8 3 9 6, akkor az algoritmus a következő iterációkkal rendez:

```

1
  7 5 4 8 3 9 6
1      7
  3 5 4 6 8 9
1    5 7
  3 4 6 8 9 stb..

```

Várható futási időt nyilvánvalóan a mutatók átállításának a költsége határozza meg, maga a beszúrás a mutatók alapján konstans időben megtehető, így a beszúrások összköltsége lineáris. A visszafele elemzés alapötlete, hogy azt vizsgáljuk mennyi a költség, ha nem beszűrünk hanem töröljük az elemeket (a két költség megegyezik, csak ezt az utóbbit könnyebb kiszámolni). Tehát adottak a sorozatban rendezett x_1, x_2, \dots, x_i számok és egyenletes eloszlás alapján törölünk egy elemet, azaz minden elemet $1/i$ valószínűséggel. Eddig az x_{i+1}, \dots, x_n elemeket már töröltük, tehát róluk már mutat mutató a jelenlegi elemek közötti intervallumokba.

Az egyenletes eloszlás miatt a mutató átállítások várható száma: $(n-i) / i$. Minden $j \in x_{i+1}, \dots, x_n$ -re annak a valószínűsége, hogy j -t átállítjuk $1/i$, tehát az adott elem átállításának várható értéke $1/i$. Viszont az összes átállítások várható értéke, ezen várható értékek összege, tehát $E(\text{átállítás száma}) = (n-i) / i$.

Következésképpen az algoritmus futása során az összes átállítás várható költsége, így az algoritmus futási ideje legfeljebb $\sum_{i=1}^n (n-i) / i \leq \sum_{i=1}^n n/i = n \sum_{i=1}^n 1/i = O(n \log n)$.

KONVEX BUROK


Def: Egy ponthalmaz konvex, ha bármely két pontjára az őket összekötő szakasz bármely pontja is a ponthalmazban van.

Def: Egy ponthalmaz konvex burka a legszűkebb olyan konvex halmaz, amely a pontok mindegyikét tartalmazza.

A következő véletlenített algoritmust használhatjuk adott ponthalmaz konvex burkának meghatározására. (A két dimenziós problémát tekintjük, de az eljárás kiterjeszhető több dimenzióra is)

1. Véletlen sorrendbe állítjuk a pontokat
2. Vesszünk 3 pontot, és vesszük egy belső pontját az általuk meghatározott háromszögnek pl a súlyközéppontját (P_0)
3. Minden pontra meghatározzuk, hogy melyik tartományba esik a P_0 és a csúcsok által meghatározott egyenesekkel meghatározott tartományok közül, ezt számon tartjuk egy kétirányú mutatóval.
4. Vesszük sorban a pontokat. Az adott pontot beszűrjük a konvex burokba felhasználván, hogy tudjuk melyik tartományban van.
 - 4.a Ha az új pont az eddigi burkon belül esik, akkor nincs semmi teendőnk. (Ezt konstans időben meghatározhatjuk, mivel tudjuk melyik tartományban van).
 - 4.b Ha az új pont kívülre esett, akkor meg kell vizsgálni hogy keletkezett-e konvex burk rész (P_j), vagy belső burk rész (P_i), ha igen akkor azt a pontot ki kell szedni a burokalkotók sorából. Majd át kell állítani a mutatókat az új tartományoknak megfelelően.

A következő ábrán a kék színnel jelölt két él hatására a belső P_i pontot és a hozzá tartozó éleket kell törölni. Ha viszont nem a kék hanem a zöldes él kerül felvételre, akkor P_i -t és P_j -t is törölni kell, és a hozzájuk tartozó éleket (itt először az A F1 és a B F1 él kerül felvételre, majd a B pontnál látjuk hogy konkáv burok rész van, így B csúcsot és éleit is törölni kell, ekkor jön létre C F1 él)



Az algoritmus futási ideje két részből adódik össze:

Az él törlésének száma. Ez lineáris, hiszen csak ha már létre lett hozva egy él akkor törölhetjük, viszont lépésenként legfeljebb 2 élet hozunk létre és n lépés van.

Az átállított mutatók száma. Ennek összeszámolásához ismét a visszafele elemzést használjuk. Tegyük fel, hogy töröljük a pontokat a konkáv burokból nem pedig beszúrjuk őket. Amikor $n-i$ pontot már kitöröltünk, akkor annak a valószínűsége, hogy a kitörölt pontok közül egy adott P pontra a (P_0, P) mutatót át kell állítani megegyezik a valószínűséggel, hogy annak az élnek valamely végpontját töröljük, amely él P tartományát meghatározza. Ennek pedig $2/i$ a valószínűsége. Tehát a várható értéke az átállított mutatók számának legfeljebb $2n/i$ az i -dik lépésben, így összesen $O(n \log n)$, azaz az algoritmus futási ideje is: $O(n \log n)$.

Megjegyzés A feladat két dimenzióban megoldható determinisztikus algoritmussal is $O(n \log n)$ időben.

Készítette: Sánta Róbert