

## S. 65.

Marussy Kristóf 12. évfolyam  
Budapest, Szent István Gimnázium  
E-mail: kris7topher@gmail.com

# 1. Az algoritmus formális leírása

## 1.1. Az aztékok formális nyelve

Tekintsük a  $\Sigma = \{<, >\}$  ábécét, és felettte az  $L \subseteq \Sigma^*$  formális nyelvet, melyre

1. ha  $a \in L$ , akkor  $a$  azonos számú  $<$  és  $>$  jelet tartalmaz;
2. ha  $a \in L$  és  $b \sqsubseteq a$  prefixe, akkor  $b$  legalább annyi  $<$  jelet tartalmaz, mint  $>$  jelet,
3. az  $e$  üres szó nem eleme  $L$ -nek.

A megalkotott  $L$  nyelv az Ometeotl szabályai által megengedett jelsorozatokból áll. Az egyszerűség kedvéért nevezzük  $L$  elemeit *jó* szavaknak.

**1. lemma.** *Az jó szavak mind páros sok jelből állnak.*

*Bizonyítás.* Az állítás a kiegyensúlyozottsági feltétel következménye: ha egy szó  $k$  darab  $<$  jelet tartalmaz, akkor  $k$  darab  $>$  jelet kell tartalmazzon, tehát összesen  $2k$  darab jelből áll.  $\square$

**2. lemma.** *Bármely jó szónak  $<$  prefixe.*

*Bizonyítás.* A bizonyítást indirekt végezzük.

Tegyük fel, hogy egy  $a$  jó szónak  $>$  prefixe. Ekkor  $a$ -nak van olyan prefixe, mely több  $>$  jelet tartalmaz, mint  $<$  jelet. Ez ellentmondás, mert sérülne Ometeotl 2. feltétele.

Tehát egyetlen jó szónak sem lehet  $>$  prefixe. Mivel  $e$  nem jó szó és  $\Sigma$  csak két jelből áll, minden jó szónak  $<$  prefixe.  $\square$

Az egyszerűség kedvéért azt, hogy a feladat  $R$  végtelen listájában  $a$  jó sztring vagy megelőzi  $b$  jó sztringet, vagy  $a = b$ , jelöljük  $a \leq_R b$  formában.

## 1.2. Dinamikus programozás alkalmazása

Vezessük be a  $\sigma^k = \underbrace{\sigma\sigma\cdots\sigma}_{k \text{ darab}}$  jelölést ( $\sigma^0 = e$ ). Jelentse  $L_{i,j}$  azon  $2j$  hosszúságú jó szavak halmazát, melyeknek  $(<)^i$  prefixe. Legyen  $n_{i,j} = |L_{i,j}|$ . Vegyük észre, hogy  $L_{0,j}$  a pontosan  $2j$  hosszúságú jó szavak halmaza. Az 1. lemma miatt

$$\bigcup_{j=1}^{\infty} L_{0,j} = L.$$

A  $\leq_R$  rendezés definíciója szerint igazak az

$$\forall a \in L_{0,j}; b \in L_{0,J}; j \leq J : \quad a \leq_R b, \quad (1)$$

$$\forall a \in L_{I,j}; b \in L_{i,j} \setminus L_{I,j}; i < I : \quad a \leq_R b \quad (2)$$

állítások.

**3. lemma.** Az  $n_{i,j}$  a következő, rekurzív alakban adható meg:

$$n_{i,j} = \begin{cases} n_{1,j} & \text{ha } i = 0, \\ 1 & \text{ha } i = j = 1, \\ 0 & \text{ha } i > j, \\ n_{i+1,j} + n_{i-1,j-1} & \text{egyébként.} \end{cases} \quad \begin{matrix} (3a) \\ (3b) \\ (3c) \\ (3d) \end{matrix}$$

*Bizonyítás.* A 2. lemma miatt a (3a) eset triviális.

Ha  $i = j = 1$ , csak egy jó szót találhatunk, ez a  $\langle \rangle$ . Tehát (3b) teljesül.

Ometeotl 1. feltétele miatt egy  $2j$  hosszúságú jó szóban pontosan  $j$  dara  $\langle$  jel van, több semmiképp sem lehet; ezzel (3c)-t is beláttuk.

Már csak  $0 < i \leq j$  maradt, azaz a (3d) eset. Vegyük észre, hogy  $i > 0$  esetén  $L_{i,j}$  elemei kétfélék lehetnek: vagy  $\langle \rangle^i \langle$ , vagy  $\langle \rangle^i \rangle$  prefixük. Azon jó szavak, melyeknek  $\langle \rangle^i \langle = \langle \rangle^{i+1}$  prefixe, pontosan az  $L_{i+1,j}$  halmaz elemei. Tehát

$$\begin{aligned} n_{i,j} &= |L_{i,j}| \\ &= |L_{i+1,j}| + |L_{i,j} \setminus L_{i+1,j}| \\ &= n_{i+1,j} + |L_{i,j} \setminus L_{i+1,j}|, \end{aligned}$$

azaz elegendő

$$n_{i-1,j-1} = |L_{i,j} \setminus L_{i+1,j}|$$

bizonyítása. Ezt egy  $L_{i-1,j-1} \longleftrightarrow L_{i,j} \setminus L_{i+1,j}$  bijekció megkonstruálásával látjuk be. Ugyanis ha egy  $\langle \rangle^n \rangle X$  alakú szó ( $X \in \Sigma^*$ ) eleme  $L_{i,j} \setminus L_{i+1,j}$ -nek, akkor az  $\langle \rangle^{i-1} X$  szó  $2(j-1)$  hosszúságú és  $L_{i-1,j-1}$  eleme; Ometeotl mindkét szabálya érvényes marad. Analóg, ellenkező irányú állítás is belátható. Következésképp a két halmaz elemeinek száma azonos.  $\square$

A 3. lemma szerint, dinamikus programozás felhasználásával könnyűszerrel kiszámíthatjuk  $n_{i,j}$  értékeit. A SEGÉDTÖMB-KISZÁMOL eljárás épp ezt teszi, egy  $max + 1 \times max + 1$  méretű  $N$  tömb segítségével. Az eljárás végén az  $N[i, j] = n_{i,j}$  lesz minden  $0 \leq i \leq max, 0 \leq j \leq i$  indexre.

SEGÉDTÖMB-KISZÁMOL( $N, max$ )

```

1   $N[0, 0] = 0$ 
2  for  $i = 1$  to  $max$ 
3       $N[i, i] = 1$ 
4  for  $j = 1$  to  $max$ 
5       $N[0, j] = N[1, j]$ 
6      for  $k = j + 1$  to  $max$ 
7           $N[k - j, k] = N[k - j + 1, k] + N[k - j - 1, k - 1]$ 
```

A SEGÉDTÖMB-KISZÁMOL a dinamikus programozásban megszokott „táblázat ki-töltést” nem soronként, hanem átlósan végzi el:

- Először az 1. sor és a 2–3. sorok ciklusa kitölti a főátló elemeit, (3b) és (3c) figyelembe vételével.
- Ezután a 4–7. sorok ciklusa a táblázat bal alsó sarka felé haladva kitölti a többi átlót.
- A (3a) esetet az 1. és 5. sorok kezelik.

Erre a haladásra azért van szükség, mert (3d) szerint egy elem a fölötte balra illetve a tőle jobbra lévő elemtől is függ.

A futásidő az egymásba ágyazott a 4–7. és a 6–7. sorbeli ciklusok miatt  $O(max^2)$ .

### 1.3. A kódolás lépései

Mivel a kódolás egyéb lépései lényegében triviálisak, elegendő azzal foglalkozni, hogyan alakítható egy tetszőleges  $\nu$  szám valamely  $x$  jó szóvá; azaz hogy találhatjuk meg az  $x$  jó szót, hogy pontosan  $\nu$  darab olyan  $x'$  jó szó legyen, melyre  $x' \leq_R x$ . Így a feladatban szereplő választás az  $R$  listából mindig a  $\nu - 1$ . szám választását fogja jelenteni; az  $R$  lista ugyanis 0-tól indexelt, míg a  $<>$  szó  $\nu = 1$ -hez fog tartozni.

Először meghatározzuk  $x$  hosszát. Az (1) miatt  $|x| = 2j$ , ha

$$\sum_{k=0}^{j-1} n_{0,k} < \nu \leq \sum_{k=0}^j n_{0,k}. \quad (4)$$

Ezt a műveletet végzi a KÓDOLÁS-SZÓHOSSZ eljárás, mely a  $\mu$  változóban megadja, hogy  $x$  a  $2j$  hosszúságú jó szavak között hanyadik helyen áll az  $R$  listában.

KÓDOLÁS-SZÓHOSSZ( $N, \nu, \mu$ )

```

1   $j = 0$ 
2   $sum = 0$ 
3  while  $sum + N[0, j] < \nu$ 
4       $sum = sum + N[0, j]$ 
5       $j = j + 1$ 
6   $\mu = \nu - sum$ 
7  return  $j$ 
```

Azt, hogy a  $2j$  hosszúságú jó szavak közül melyik a  $\mu$ ., egy rekurzió segítségével állapítjuk meg. Az alapötlet a következő: legyen  $x = (<)^i > X$ . Ekkor a (2) egyenlőtlenség és a 3. lemma bizonyításában vázolt bijekció miatt

$$\mu = n_{i+1,j} + \mu', \quad (5)$$

ahol  $\mu'$  azt mutatja, hogy a  $x' = (<)^{i-1} X$  szó hanyadik helyen áll a  $2j-2$  hosszúságú szavak között. Természetesen elvárjuk, hogy

$$0 < \mu' \leq n_{i-1,j-1}. \quad (6)$$

A  $j = 1$  esetet némiképp speciálisan kell kezeljünk, ott (5) nem alkalmazható, mivel az  $X$  az üres szó lenne, amely nem jó szó. Szerencsére  $j = 1$  esetén csak  $\mu = 1$  lehetséges, melyre  $i = 1$ , vagyis a keresett szó a  $\langle \rangle$ .

**4. lemma.** *A  $j, \mu$  változók, valamint az (5) és (6) egyenletek egyértelműen meghatározzák  $i$  értékét.*

*Bizonyítás.* Alkalmazzunk indirekt bizonyítást! Tegyük fel, hogy  $i = i_1$  és  $i = i_2$  kielégítik az (5) és (6) egyenleteket.

Az általánosság megszorítása nélkül feltehetjük azt is, hogy  $i_2 = i_1 + 1$ . (Ha  $i_1 < i_2$ , felcseréljük őket; ha pedig  $i_2 - i_1 > 1$ , akkor bármely  $i_1 < i'_2 < i_2$  is megfelel a feltételeknek.) Így azt kapjuk, hogy

$$0 < \mu - n_{i_1+1,j} \leq n_{i_1-1,j-1}, \quad (7)$$

$$0 < \mu - n_{i_2+1,j} = \mu - n_{i_1+2,j} \leq n_{i_2-1,j-1} = n_{i_1,j-1}, \quad (8)$$

azaz

$$n_{i_1+1,j} - n_{i_1+2,j} < \mu - n_{i_1+2,j} \leq n_{i_1,j-1}. \quad (9)$$

Ha  $i_1 < j$ , (3d) miatt

$$n_{i_1+1,j} < n_{i_1+2,j} + n_{i_1,j-1} = n_{i_1+1,j}, \quad (10)$$

ami ellentmondás.

Hátra van még az  $i_1 = j$  eset, de akkor  $i_2 > j$ , azaz  $\langle \rangle^{i_2}$  nem lehet  $x$  prefixe. Vagyis ismét ellentmondásra jutottunk.

A fentiek szerint legfeljebb egy  $i$  (és hozzá tartozó  $\mu'$ ) elégítheti ki a feltételeket. Mivel  $x = \langle \rangle^i X$  és  $x' = \langle \rangle^{i-1} X$  jó szavak, ezért  $i$  és  $\mu'$  is jól definiált, vagyis pontosan egy ilyen  $i$  létezik.  $\square$

A megfelelő  $i$  és  $\mu'$  megkeresését végzi a KÓDOLÁS-PREFIXHOSSZ eljárás.

KÓDOLÁS-PREFIXHOSSZ( $N, j, \mu, \mu'$ )

```

1  if  $j = 1$ 
2      return 1
3   $i = j$ 
4  while  $N[i, j] < \mu$ 
5       $i = i - 1$ 
6  if  $i = j$ 
7       $\mu' = \mu - 0$ 
8  else  $\mu' = \mu - N[i + 1, j]$ 
9  return  $i$ 
```

Ennek a két eljárásnak a segítségével könnyedén előállíthatjuk az  $x$  jó szó  $\nu$ -höz. Először meghatározzuk  $\nu$ -höz  $j^{(1)}$  és  $\mu^{(1)}$  értékét KÓDOLÁS-SZÓHOSSZ segítségével (a felső index az első iterációt jelöli). Majd KÓDOLÁS-PREFIXHOSSZ megadja  $x =$

$j$	$\mu$	$i$	$\mu'$	$x$
3	4	1	1	<>????
2	1	2	1	<><<>?
1	1	1		<><<>>

1. táblázat. A KÓDOLÁS-PREFIXHOSSZ eljárás hívásai a  $\nu = 7$  esetben.

$x^{(1)}$  egy prefixét közvetett módon  $i^{(1)}$  és  $\mu^{(1)}$  változókkal. Az  $x$  szó egészét úgy kaphatjuk meg, hogy meghatározzuk  $x' = x^{(2)}$ -t; így következik az újabb iteráció  $j^{(2)} = j^{(1)} - 1$  és  $\mu^{(2)} = \mu^{(1)}$  bemenetekkel. Pontosabban: összefűzve az  $(<)^{i^{(1)}}>$  és az  $x^{(2)}[i^{(1)}..2j^{(2)}]$  sztringeket kapjuk meg  $x^{(1)}$ -et. A rekurziót az indexek növelésével folytathatjuk a  $k$ . iterációig, amíg  $j^{(k+1)} = 0$  nem lesz.

Ezt a módszert követi a KÓDOLÁS eljárás.

KÓDOLÁS( $N, \nu$ )

```

1   $j^{(1)} = \text{KÓDOLÁS-SZÓHOSSZ}(N, \nu, \mu^{(1)})$ 
2   $i^{(0)} = 1$ 
3   $k = 1$ 
4  while  $j^{(k)} > 0$ 
5       $i^{(k)} = \text{KÓDOLÁS-PREFIXHOSSZ}(N, j^{(k)}, \mu^{(k)}, \mu^{(k+1)})$ 
6      for  $\ell = 1$  to  $i^{(k)} + 1 - i^{(k-1)}$ 
7          print „<”
8      print „>”
9       $j^{(k+1)} = j^{(k)} - 1$ 
10      $k = k + 1$ 
```

A ciklus a 6-8. sorokban mindig kiírja  $x$  már megismert prefixét, a 2. sor pedig az első iteráció speciális kezelését kerüli el.

Példának vegyük a  $\nu = 7$  esetet. Először a KÓDOLÁS-SZÓHOSSZ futtatásával kapjuk, hogy  $j^{(1)} = 3$  és  $\mu^{(1)} = 4$ . Az 1. táblázat mutatja a KÓDOLÁS-PREFIXHOSSZ hívások eredményeit.

#### 1.4. A dekódolás lépései

A dekódolás a kódolás lépéseinek fordított sorrendű elvégzésével történik. Pontosabban: a KÓDOLÁS-PREFIXHOSSZ eljárás 7. és 8. sorában, valamint a KÓDOLÁS-SZÓHOSSZ eljárás 6. sorában levont értékek kiszámítása és összeadása után kapható meg  $\nu$  értéke egy adott  $x$ -hez.

Ezt a műveletet a DEKÓDOLÁS eljárás végzi.

DEKÓDOLÁS( $N, x$ )

```

1   $\nu = 1$ 
2   $k = 1$ 
3   $j^{(1)} = \frac{|x|}{2}$ 
4   $i^{(1)} = 0$ 
5  for  $p = 1$  to  $|x|$ 
6      if  $x[p] == "<"$ 
7           $i^{(k)} = i^{(k)+1}$ 
8      elseif  $x[p] == ">"$ 
9          if  $i^{(k)} < j^{(k)}$ 
10              $\nu = \nu + N [i^{(k)} + 1, j^{(k)}]$ 
11             else  $\nu = \nu + 0$ 
12              $\nu = \nu - N [0, j^{(k)} - 1]$ 
13              $i^{(k+1)} = i^{(k)} - 1$ 
14              $j^{(k+1)} = j^{(k)} - 1$ 
15              $k = k + 1$ 
16 return  $\nu$ 

```

A változók felső indexes jelölése csupán az érthetőség kedvéért történik, az indexek megfelelnek a KÓDOLÁS eljárás során megjelenőknek. A  $\nu = 1$  kezdőérték az 1. sorban azt biztosítja, hogy magát a dekódolt szót is beleszámítsuk  $\nu$  értékébe annak definíciója szerint (hiszen  $x \leq_R x$ ). A 10. és 11. sorok a KÓDOLÁS-PREFIXHOSSZ, míg a 12. sor a KÓDOLÁS-SZÓHOSSZ eljárás által levont értékeket adja hozzá  $\nu$ -hoz.

## 2. Az implementáció

Az algoritmusokat C++ nyelven implementáltam, a fordításhoz GCC (g++) fordítóprogramot használtam.

A programkódom (`main.cxx`) a KÓDOLÁS és DEKÓDOLÁS eljárásokon kívül természetesen tartalmazza a bementet beolvasásához, illetve a betűcsoportok, számok és  $L$ -beli szavak egymásba alakításához szükséges eljárásokat is.

A program alapesetben a bementet a `S65.be` fájlból olvassa, a kimenetet pedig a `S65.ki` fájlba írja. Ez a fordításkor bizonyos preprocesszor-szimbólum definiálásával írható felül, melyeket a 2. táblázat tartalmaz.

kapcsoló	leírás	alapérték
<code>-DBE="fájlnev"</code>	Bemeneti fájl neve.	<code>S65.be</code>
<code>-DKI="fájlnev"</code>	Kimeneti fájl neve.	<code>S65.ki</code>
<code>-DSTDIO=1</code>	Standard ki- és bemenet használata a fájlok helyett.	kikapcsolt

2. táblázat. Kapcsolók az I/O műveletek céljainak módosításához.