

Szókombinatorikai alkalmazások

Kása Zoltán

Babeş-Bolyai Tudományegyetem, Kolozsvár

E-mail: kasa@cs.ubbcluj.ro

<http://www.cs.ubbcluj.ro/~kasa>

véges szó az \mathcal{A} ábécé fölött:

$$w = w_1w_2 \dots w_N, \quad w_i \in \mathcal{A}, 1 \leq i \leq N.$$

u *részszo* w -nek, ha : $\exists x, y \in \mathcal{A}^*: w = xuy$

$F(w)$ a w nem üres részszoainak a halmaza
 $F_n(w)$ a w szó n hosszúságú részszoainak a halmaza

w *részszo-bonyolultsága*:

$$f_w(n) = \#F_n(w), \quad 1 \leq n \leq |w|$$

$w = abaaba$

$F_1(w) = \{a, b\}$, $F_2(w) = \{ab, aa, ba\}$,

$F_3(w) = \{aba, baa, aab\}$

végtelen szó:

$$u = u_0u_1u_2 \dots u_n \dots, \quad u_i \in \mathcal{A}$$

$$f_u(n) = \#F_n(u) \quad \text{részszó-bonyolultság}$$

Példák:

1) *Fibonacci-szó:* $\sigma(0) = 01, \sigma(1) = 0$

0

01

010

01001

01001010

$$u_F = \underbrace{01001010}_{n} \underbrace{01001}_{n} \dots$$

$$f_{u_F}(n) = n + 1$$

2) *Hatványzó:*

$$u_p = 010011000111 \dots \underbrace{0 \dots 0}_n \underbrace{1 \dots 1}_n \dots$$

$$f_{u_p}(n) = \frac{n(n+1)}{2} + 1$$

3) *Champanowne-szó:*


$$u_C = 0 \ 1 \ 10 \ 11 \ 100 \ 101 \ 110 \ 111 \ \dots$$

$$f_{u_C}(n) = 2^n$$

$\underbrace{abc} \underbrace{abc} \underbrace{abc} \dots \underbrace{abc} \dots$ *periodikus*
 $aaaaaba \underbrace{abc} \underbrace{abc} \underbrace{abc} \dots \underbrace{abc} \dots$ *végperiodikus*

Ha $f_u(n) \leq n$ minden $n \geq n_0$ -ra, akkor u (vég)periodikus.

Sturm típusú szavak amelyekre $f_u(n) = n + 1$.



α irrational

001010...

3-dimenzióban: $n^2 + n + 1$

S. Ferenczi, C. Mauduit: $u = u_0u_1u_2 \dots u_n \dots$,
 $u_i \in \{0, 1\}$, hozzárendeljük $\theta = 0.u_0u_1 \dots u_n \dots$
 2-es alapú számrendszerben. *Ha u Sturm-szó,*
 akkor θ *transzcendens szám.*

Tribonacci-szó:

$$\sigma(0) = 01, \quad \sigma(1) = 02, \quad \sigma(2) = 0$$

0

01

0102

0102010

0102010010201

...

$$\begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix}$$

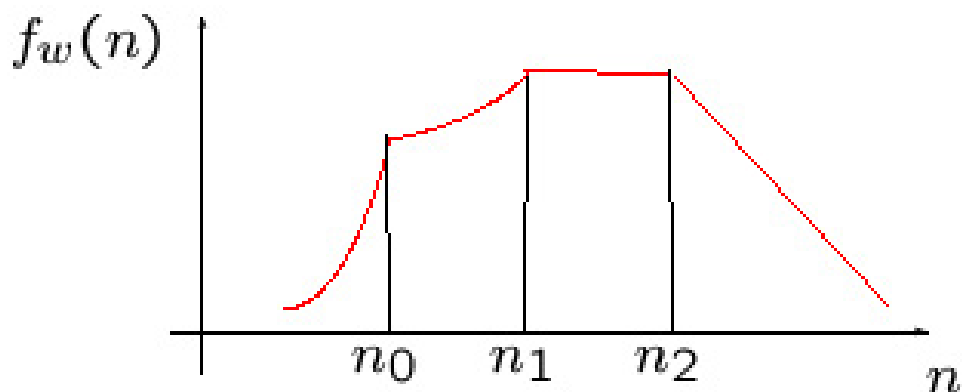
$$\begin{vmatrix} 1-x & 1 & 0 \\ 1 & -x & 1 \\ 1 & 0 & -x \end{vmatrix} = 0$$

karakterisztikus
polinom,
gyökei: $\beta > 1$,
 $\alpha, \bar{\alpha}$ komplexek

$$\mathcal{R} = \left\{ \sum_{i \geq 0} \varepsilon_i \alpha^i; \varepsilon_i = 0, 1; \varepsilon_i \varepsilon_{i+1} \varepsilon_{i+2} = 0 \right\} \subset \mathbf{C}.$$



n	1	2	3	4	5
11111	1	1	1	1	1
11112	2	2	2	2	1
21122	2	4	3	2	1
21211	2	3	3	2	1
22112	2	4	3	2	1
22211	2	3	3	2	1



maximális bonyolultság:

$$C(w) = \max\{f_w(n) \mid n \geq 1\}$$

globális maximális bonyolultság \mathcal{A}^N -ben:

$$K(N) = \max\{C(w) \mid w \in \mathcal{A}^N\}$$

$$R(N) = \{i \in \overline{1, N} \mid \exists w \in \mathcal{A}^N : f_w(i) = K(N)\}$$

$M(N)$: azon \mathcal{A}^N -beli szavak száma, amelyek maximális bonyolultsága egyenlő a globális maximális bonyolultsággal

N	$K(N)$	$R(N)$	$M(N)$
1	1	1	2
2	2	1	2
3	2	1, 2	6
4	3	2	8
5	4	2	4
6	4	2, 3	36
7	5	3	42
8	6	3	48
9	7	3	40
10	8	3	16
11	8	3, 4	558
12	9	4	718
13	10	4	854
14	11	4	920
15	12	4	956
16	13	4	960
17	14	4	912
18	15	4	704
19	16	4	256
20	16	4, 5	79006

1. tétel

Ha $\#\mathcal{A} = q$ és $q^k + k \leq N \leq q^{k+1} + k$, akkor $K(N) = N - k$.

2. tétel

Ha $\#\mathcal{A} = q$ és $q^k + k < N < q^{k+1} + k + 1$, akkor $R(N) = \{k + 1\}$;

ha $N = q^k + k$, akkor $R(N) = \{k, k + 1\}$.

De Bruijn-gráfok

\mathcal{A} q -betűs ábécé, a de Bruijn gráf::

$$B(q, k) = (V(q, k), E(q, k)),$$


ahol $V(q, k) = \mathcal{A}^k$ csúcsok halmaza,

$E(q, k) = \mathcal{A}^{k+1}$ élek halmaza.


Van él $x_1x_2 \dots x_k$ -ből $y_1y_2 \dots y_k$ -ba,

ha $x_2x_3 \dots x_k = y_1y_2 \dots y_{k-1}$,

és az él $x_1x_2 \dots x_ky_k$.



$B(2, 2)$



$B(2, 3)$

út: 001, 011, 111, 110 \implies szó: **001110**

Hamilton-út:


000, 001, 011, 111, 110, 101, 010, 100 \implies

szó: **0001110100**



$B(q, k)$ -ban leghosszabb út (amely Hamiltonian-út) egy de Bruijn-szót eredményez.

nem irányított de Bruijn-gráfok

hálózati modellek



(3-dimenziós hiper)kocka



4-dimenziós hiperkocka

3. tétel

Ha $\#\mathcal{A} = q$ és $q^k + k \leq N \leq q^{k+1} + k$, akkor $M(N)$ egyenlő a különböző $N - k - 1$ hosszúságú utakkal a $B(q, k + 1)$ gráfban.

Pl.

$$k = 2 : 2^2 + 2 \leq N \leq 2^3 + 2$$

$N = 6$, $N - k - 1 = 3$, összesen 36 különböző 3 hosszúságú út van $B(2, 3)$ -ban.

000, 111, 010, 101-ből kiindulva
4 különböző út van, máshonnan 5

4. tétel

Ha $N = 2^k + k - 1$, akkor $M(N) = 2^{2^{k-1}}$.

Általánosítás:

Ha $N = q^k + k - 1$, akkor $M(N) = (q!)^{q^{k-1}}$.

teljes bonyolultság: $\mathbf{K}(w) = \sum_{i=1}^{|w|} f_w(i)$

- $C \neq 1, 2, 4$, akkor \exists egy nem triviális w úgy, hogy $\mathbf{K}(w) = C$
- $C \neq 1, 2, 4, 6, 10, 18, 22$, akkor \exists egy nem triviális $w \in \mathcal{A}^*$, $\#\mathcal{A} = 2$, úgy, hogy $\mathbf{K}(w) = C$

$ w = 5$ C	5	6	7	8	9	10	11	12	13	14	15
$f_5(C)$	5	0	0	0	60	0	200	400	1140	1200	120

$f_k(C) \neq 0$, $\forall C$ -re úgy, hogy $b_k \leq C \leq \frac{k(k+1)}{2}$

$$k = \frac{\ell(\ell+1)}{2} + 2 + i, \ell \geq 2, 0 \leq i \leq \ell \Rightarrow$$

$$b_k = \frac{\ell(\ell^2-1)}{2} + 3\ell + 2 + i(\ell+1)$$

$k = 5 = \frac{2 \cdot 3}{2} + 2 + 0$ so $\ell = 2, i = 0$, then
 $b_5 = \frac{2 \cdot 5}{2} + 3 \cdot 2 + 2 + 0 = 11$.

F. Levé, P. Séébold, 2000

$$\mathbf{K}(w) = \sum_{k=1}^{|w|} f_w(k)$$

$$\mathbf{K}_u^+(n) = \max_i \mathbf{K}(u_i u_{i+1} \dots u_{i+n-1})$$

$$\mathbf{C}(w) = \max_{k=1}^{|w|} f_w(k)$$

$$\mathbf{C}_u^+(n) = \max_i \mathbf{C}(u_i u_{i+1} \dots u_{i+n-1})$$

u nem végperiodikus:

$$f_u(n) \geq n + 1$$

$$\mathbf{C}_u^+(n) \geq \left\lfloor \frac{n}{2} \right\rfloor + 1$$

$$\mathbf{K}_u^+(n) \geq \left\lfloor \frac{n^2}{4} + n \right\rfloor$$

u Sturm:

$$f_u(n) = n + 1$$

$$\mathbf{C}_u^+(n) = \left\lfloor \frac{n}{2} \right\rfloor + 1$$

$$\mathbf{K}_u^+(n) = \left\lfloor \frac{n^2}{4} + n \right\rfloor$$

AAC	CAA	AUC	CUA
AAG	GAA	AUG	GUA
AAU	UAA	AUU	UUA
ACC	CCA	AGC	CGA
ACG	GCA	AGG	GGA
ACU	UCA	AGU	UGA
CAG	GAC	CUG	GUC
CAU	UAC	CUU	UUC
CCG	GCC	CGG	GGC
CCU	UCC	CGU	UGC
GAU	UAG	GUU	UUG
GCU	UCG	GGU	UGG

genetikai kód

4 alapelem

DNS

A (adenine), *T* (thymine), *G* (guanine), *C* (cytosine)

RNS

A (adenine), *U* (uracil), *G* (guanine), *C* (cytosine)

... UGUCGUAAG...

UGU, GUC, UCG, ...

(B. Hayes: *The invention of the genetic code*,
American Scientist, 1998, vol. 86 no. 1)

jobbspeciális részszó többféleképpen lehet folytatni jobbról

010010100100101001010...

010 jobbspeciális részszó: *0100*, *0101*

100 nem jobbspeciális: *1001*

(bal-, jobb-, bi-) speciális részszavak szerepe
DNS és RNS molekulákban

010 bispeciális

0100, *0101*

0010, *1010*

mintaillesztés



E-mail: kasa@cs.ubbcluj.ro
<http://www.cs.ubbcluj.ro/~kasa>