Komprese dat

Jan Outrata

KATEDRA INFORMATIKY
UNIVERZITA PALACKÉHO V OLOMOUCI

přednášky

Kontextové (context-based) metody

Kontextové (context-based) metody

- výskyt symbolu na vstupu není nezávislý na výskytu ostatních symbolů

$=$ pro modelování symbolu na vstupu využití kontextu délky $k =$ posloupnost (bezprostředně) předchozích k symbolů $\rightarrow$ Markovův model k-tého řádu

$\rightarrow$ větší rozdíly v (podmíněných) pravděpodobnostech výskytu symbolů v kontextu jiných symbolů $\rightarrow$ lepší predikce symbolu (např. na konci slova) $\rightarrow$ vyšší míra komprese

Příklad

vstup $barbaraabarboraubaru$, $A = \{a, b, r, u, o\}$
$f(a) = \frac{7}{20}$, $f(b) = \frac{5}{20}$, $f(r) = \frac{5}{20}$, $f(u) = \frac{2}{20}$, $f(o) = \frac{1}{20}$,
$f(a|a) = \frac{1}{7}$, $f(b|a) = \frac{1}{7}$, $f(r|a) = \frac{4}{7}$, $f(u|a) = \frac{1}{7}$, $f(a|b) = \frac{4}{5}$, $f(o|b) = \frac{1}{5}$, $f(a|r) = \frac{2}{5}$,
$f(b|r) = \frac{2}{5}$, $f(u|r) = \frac{1}{5}$, $f(b|u) = 1$, $f(r|o) = 1$, ostatní $f = 0$
$f(b|aa) = 1$, $f(a|ab) = 1$, $f(a|ar) = \frac{1}{4}$, $f(b|ar) = \frac{2}{4}$, $f(u|ar) = \frac{1}{4}$, $f(b|au) = 1$,
$f(r|ba) = 1$, $f(r|bo) = 1$, $f(a|ra) = \frac{1}{2}$, $f(u|ra) = \frac{1}{2}$, $f(a|rb) = \frac{1}{2}$, $f(o|rb) = \frac{1}{2}$,
$f(a|ub) = 1$, $f(a|or) = 1$, ostatní $f = 0$

PPM (Prediction with partial match)

- zvyšující se pravděpodobnost výskytu symbolu s delším kontextem (menší počet symbolů v něm), ale počet kontextů délky k je $|A|^k$ (A abeceda symbolů)

$\rightarrow$ nezjišťovat pravděpodobnosti výskytu symbolu pro všechny kontexty dané délky, ale pouze pro kontexty na vstupu

$=$ adaptivní modelování pravděpodobností výskytu symbolů ve zkracujícím se kontextu jako posloupnosti bezprostředně předchozích symbolů

- Cleary, Witten, 1984
- speciální (escape) symbol ε abecedy značící neexistující/první výskyt symbolu na vstupu v aktuálním kontextu
- průběžné odhady (podmíněných) pravděpodobností $P(a_i|c^k)$ a distribučních funkcí/ kumulovaných pravděpodobností $F_X(i|c^k)$ výskytu symbolů z abeced $A|c^k \subseteq A \cup \{\varepsilon\} = \{a_1, a_2, \ldots, a_n, \varepsilon\}$ jako náhodných proměnných $X(a_i|c^k) = i|c^k$ s frekvencemi/ četnostmi $f(a_i|c^k) = \frac{n(a_i|c^k)}{\sum_{j=1}^{|A|c^k|} n(a_j|c^k)}$ výskytu symbolu $a_i \in A|c^k$ v kontextu c_k délky k
  - výskyt v kontextu c^0 = výskyt (bez kontextu)
  - výskyt v kontextu c^{-1} = neexistující/první výskyt, $A|c^{-1} = A$, $n(a_i|c^{-1}) = 1$ pro všechny $a_i \in A$

PPM (Prediction with partial match)

while načti ze vstupu symbol $a \in A$ **do**
$k \leftarrow k_{max} \leftarrow \min\{K, \text{počet načtených symbolů} - 1\}$;
while $k \geq 0 \wedge n(a|c^k) = 0$ pro (aktuální) kontext c^k symbolu a **do**
zapiš na výstup kód symbolu ε v kontextu c^k;
$k \leftarrow k - 1$;
zapiš na výstup kód symbolu a v kontextu c^k;
// algoritmus datové reprezentace $n(a|c^{k_{max}})$ nebo
$n(a|c^l) \leftarrow n(a|c^l) + 1$ pro všechny kontexty $c^l, k_{max} \geq l \geq 0$ symbolu a;

- $f(\varepsilon|c^k)$? ze začátku (relativně) velká, s počtem zpracovaných symbolů klesající
  - metoda A (PPMA): $n(\varepsilon|c^k) = 1$
  - metoda B (PPMB): $n(\varepsilon|c^k) = |A|c^k \setminus \{\varepsilon\}|$ a $n(a|c^k) \leftarrow n(a|c^k) - 1$ pro $a \in A|c^k \setminus \{\varepsilon\}$ (při $n(a|c^k) = 0$ vyřazení a z $A|c^k \setminus \{\varepsilon\}$) – větší šance nového symbolu v kontextu s více symboly v kontextu?
  - metoda C (PPMC, Moffat): $n(\varepsilon|c^k) = |A|c^k \setminus \{\varepsilon\}|$ – v průměru nejvyšší míra komprese
  - PPMP: $f(\varepsilon|c^k) =$ odhad $\frac{d_1}{d} - \frac{d_2}{d^2} + \frac{d_3}{d^3} - \ldots$, d_i symbolů vyskytujících se na vstupu i-krát, na základě Poissonova rozdělení pravděpodobnosti výskytu každého z d symbolů na vstupu
  - PPMX: přibližná verze PPMP s odhadem $\frac{d_1}{d}$, PPMC při $d_1 = 0$ nebo $d_1 = d$

PPM (Prediction with partial match)

Příklad

vstup $barbaraabarboraubaru$, $A = \{a, b, r, u, o\}, K = 3$

$n(a|c^{-1}) = n(b|c^{-1}) = n(r|c^{-1}) = n(u|c^{-1}) = n(o|c^{-1}) = 1$, ostatní $n = 0$

vstup	b	a	r	b
c^0	$n(b) = 1$	$n(a) = 1$	$n(r) = 1$	$n(b) = 2$
c^1		$n(a\|b) = 1$	$n(r\|a) = 1$	$n(b\|r) = 1$
c^2			$n(r\|ba) = 1$	$n(b\|ar) = 1$
c^3				$n(b\|bar) = 1$
výstup	$\varepsilon\|c^0 = \varepsilon, b\|c^{-1}$	$\varepsilon\|b, \varepsilon, a\|c^{-1}$	$\varepsilon\|ba, \varepsilon\|a, \varepsilon, r\|c^{-1}$	$\varepsilon\|bar, \varepsilon\|ar, \varepsilon\|r, b\|c^0 = b$

a	r	a	a	b	...
$n(a) = 2$	$n(r) = 2$	$n(a) = 3$	$n(a) = 4$	$n(b) = 3$	...
$n(a\|b) = 2$	$n(r\|a) = 2$	$n(a\|r) = 1$	$n(a\|a) = 1$	$n(b\|a) = 1$	...
$n(a\|rb) = 1$	$n(r\|ba) = 2$	$n(a\|ar) = 1$	$n(a\|ra) = 1$	$n(b\|aa) = 1$	...
$n(a\|arb) = 1$	$n(r\|rba) = 1$	$n(a\|bar) = 1$	$n(a\|ara) = 1$	$n(b\|raa) = 1$	...
$\varepsilon\|arb, \varepsilon\|rb, a\|b$	$\varepsilon\|rba, r\|ba$	$\varepsilon\|bar, \varepsilon\|ar, \varepsilon\|r, a$	$\varepsilon\|ara, \varepsilon\|ra, \varepsilon\|a, a$	$\varepsilon\|raa, \varepsilon\|aa, \varepsilon\|a, b$	...

PPM (Prediction with partial match)

$k \leftarrow k_{max} \leftarrow 0$;
while načti ze vstupu a dekóduj kód symbolu $a \in A|c^k$ v (aktuálním) kontextu c^k **do**
  if $a = \varepsilon$ **then**
    $k \leftarrow k - 1$;
  else
    zapiš na výstup symbol $a \in A$;
    `// algoritmus datové reprezentace` $n(a|c^{k_{max}})$ `nebo`
    $n(a|c^l) \leftarrow n(a|c^l) + 1$ pro všechny kontexty $c^l, k_{max} \geq l \geq 0$ symbolu a;
    $k \leftarrow k_{max} \leftarrow \min\{K, \text{počet načtených kódů symbolů}\}$;

- K? co nejvyšší? – zvyšující se pravděpodobnost výskytu symbolu s delším kontextem
  - vyšší pravděpodobnost kódování speciálního symbolu ε, delší kontexty bývají neaktuální – míra komprese nejprve s K prudce roste, ale pak mírně klesá $\rightarrow$ v praxi 5 nebo 6 pro textová data
  - PPM*: v delších kontextech bývá výskyt jen jednoho symbolu = deterministický kontext $\rightarrow$ K = délka nejkratšího, jinak délka nejdelšího nedeterministického, varianta PPMZ (Bloom)
- kódování symbolů (adaptivním) aritmetickým kódováním s dynamickým pravděpodobnostním modelem podmíněným aktuálním kontextem c^k

PPM (Prediction with partial match)

Exclusion principle

- menší abeceda znamená kratší kódy symbolů

$=$ když se načtený symbol a nevyskytl v (aktuálním) kontextu c^k délky $K \geq k \geq 0$, symboly vyskytující se v c^k, tzn. z $A|c^k \setminus \{\varepsilon\}$, lze vyřadit ze všech abeced $A|c^l$ kontextů c^l délky $-1 \leq l < k$ (protože kdyby byl býval některý načtený, zapsal by se na výstup v kontextu c^k jeho kód) – pouze pro kódování a, aktuální kontext se mění!

Příklad

při načtení prvního a nevyskytujícího se v c^0 lze vyřadit b z $A|c^{-1}$
prvního r ne v c^0 pak b, a z $A|c^{-1}$
třetího a ne v $c^3 = bar$ pak b z $A|ar, A|r, A|c^0, A|c^{-1}$
čtvrtého a ne v $c^1 = a$ pak r z $A|c^0, A|c^{-1}$
třetího b ne v $c^1 = a$ pak a, r z $A|c^0, A|c^{-1}$
...

PPM (Prediction with partial match)

Datová reprezentace $n(a|c^k), a \in A$ pro všechny kontexty $c^k, K \geq k \geq 0 = n$-ární strom $T = \langle V, E \rangle$ (n velikost A)

- listové uzly $v_l(a|c^{k_{max}}) \in V$ pro symboly $a \in A$ v kontextu $c^{k_{max}}, k_{max} = \max_{c^k} k$
- vnitřní uzly $v(a_{-i}|c^{k-i}) \in V$ pro symboly $a_{-i}, i = k, \ldots, 1$ v kontextu c^{k-i}, $c^{k-i+1} = c^{k-i}a_{-i}$, $c^1 = a_{-k}$ + kořenový uzel $v_r \in V$
- hrany $\langle v_r, v(a_{-k}|c^0) \rangle \in E$, $\langle v(a_{-i}|c^{k-i}), v(a_{-i+1}|c^{k-i+1}) \rangle \in E$ a $\langle v(a_{-1}|c^{k_{max}-1}), v_l(a|c^{k_{max}}) \rangle \in E$, nebo $\langle v_r, v_l(a|c^0) \rangle \in E$

$=$ trie $=$ v uzlech část prvku (symbol a nebo a_{-i} kontextu c^k), ne celý prvek (kontext c^k)

- $s(v(a|c^k)) = v(a|c^{k-1}), k \geq 1$ a $s(v(a|c^0)) = v_r$ pro tentýž symbol a

ILUSTRACE

PPM (Prediction with partial match)

$T \leftarrow \langle \{v_r\}, \emptyset \rangle$;
$v_p \leftarrow v_r$;
// while ...
$v_q \leftarrow v_p, k \leftarrow k_{max}$;
while $k \geq 0$ **do**
    if $k = K$ **then** $v_p \leftarrow s(v_q)$;
    if $\langle v_q, v(a|c^k) \rangle \notin E$ **then**
        $V \leftarrow V \cup \{v_l(a|c^k)\}$;
        $n(a|c^k) \leftarrow 1$;
        $E \leftarrow E \cup \{\langle v_q, v_l(a|c^k) \rangle\}$;
        if $v_q = v_p$ **then** $v_p \leftarrow v_l(a|c^k)$;
    else
        $n(a|c^k) \leftarrow n(a|c^k) + 1$;
    if $v_q \neq v_r$ **then** $v_q \leftarrow s(v_q)$;
    $k \leftarrow k - 1$;

PRIKLAD

PPM (Prediction with partial match)

- pro každý symbol $a \in A$ na vstupu přidáno 0 až K uzlů stromu $\rightarrow$ při velkém smazání a konstrukce nového z posledních několika symbolů (v praxi 2048)

PAQ

- kontext nemusí být posloupnost bezprostředně předchozích symbolů na vstupu, jako u PPM

$\rightarrow$ kombinace modelů symbolu na vstupu využívajících různé kontexty = **context mixing**

$=$ adaptivní modelování pravděpodobností výskytu binárních symbolů (bitů, z binární zdrojové abecedy) kombinací modelů pro různé kontexty

- Matt Mahoney, 2002 a další (Osnach, Ratushnyak – PAQAR, Skibiński – PAsQDa, Taylor – RK) – několik verzí (8 hlavních) a mnoho variant (pro různé typy dat), free software, postupná vylepšení místo zcela nových metod z 80. až 90. let
- kontexty např.:
  - posloupnost bezprostředně předchozích 0 až 63 bitů (po osmi) na vstupu, jako u PPM
  - bezprostředně předchozí 0 a 1 slovo na vstupu – např. znak textu
  - nejvýznamnější bity bezprostředně předchozích slov – pro multimediální data (zvuk, obraz)
  - sousední slova vícedimenzionálních dat (stejná ve stejné vzdálenosti) – např. obrazové body
  - vybraná předchozí slova („řídký kontext“) – pro různé binární soubory, např. spustitelné, již (ztrátově) komprimované aj.
- nový model z původního a 10-bitového kontextu na základě aktualizované tabulky = SSE (secondary symbol estimation) – od verze 2

PAQ

- i-tý model bitu na vstupu:
  - počty $n_i(a), a = \{\mathbf{0}, \mathbf{I}\}$ bitů v kontextu – verze 1 až 6, $n_i = n_i(\mathbf{0}) + n_i(\mathbf{I})$, $n_i(a) \leftarrow n_i(a) + 1$ a $n_i(\mathbf{I} - a) \leftarrow \lfloor 1 + \frac{n_i(\mathbf{I}-a)}{2} \rfloor$ jestliže $n_i(\mathbf{I} - a) > 2$, a hodnota modelovaného bitu
  - průběžné odhady (podmíněných) pravděpodobností $P_i(a|c), a = \{\mathbf{0}, \mathbf{I}\}$ – od verze 7: $P_i(a|c) = \frac{n_i(a)}{n_i}$
- průběžné odhady (podmíněných) pravděpodobností $P(a|c), a = \{\mathbf{0}, \mathbf{I}\}$ kombinací modelů:
  - $P(a|c) = \frac{s(a)}{s}, s = s(\mathbf{0}) + s(\mathbf{I}), s(a) = \epsilon + \sum_i w_i n_i(a)$ – verze 1 až 6, ϵ (experimentálně zjištěný) parametr pro nenulové $s(a)$, w_i váha i-tého modelu závisející na délce kontextu c – pevné (verze 1 až 3) nebo upravované pro minimalizaci chyby modelu a preferující přesnější modely (verze 4 až 6): $w_i \leftarrow \max[0, w_i + \frac{s n_i(\mathbf{I}) - s(\mathbf{I}) n_i}{s(\mathbf{0}) s(\mathbf{I})}(a - P(\mathbf{I}|c))]$
  - neuronovou sítí – od verze 7: $P(\mathbf{I}|c) = \frac{1}{1+e^{-\sum_i w_i x_i}}, x_i = \ln(\frac{P_i(\mathbf{I}|c)}{1-P_i(\mathbf{I}|c)})$, $w_i \leftarrow w_i + \mu x_i (a - P(\mathbf{I}))$, μ malá konstanta (míra adaptace)
- kódování bitů adaptivním binárním aritmetickým kódováním (QM kódováním??) s dynamickým pravděpodobnostním modelem $\{P(\mathbf{0}|c), P(\mathbf{I}, c)\}$ – podobně jako v PPM

Blokové třídění

$\sim$ Burrows-Wheelerova transformace (BWT)

- Michael Burrows, David J. Wheeler, 1994 (transformace Wheeler, 1983)
- nepoužívá (podmíněné) pravděpodobnosti výskytu symbolů v kontextu jiných symbolů ani posloupností symbolů
- blok b^k délky k: $c^{k-1}a$, a symbol na vstupu, kontext $c^{k-1} = a_{-k+1}a_{-k+2}\dots a_{-1} =$ posloupnost bezprostředně předchozích $k-1$ symbolů symbolu a

$=$ permutace bloku b^k na blok obsahující posloupnosti stejných symbolů (viz dále)

Blokové třídění

$\sim$ Burrows-Wheelerova transformace (BWT)

- Michael Burrows, David J. Wheeler, 1994 (transformace Wheeler, 1983)
- nepoužívá (podmíněné) pravděpodobnosti výskytu symbolů v kontextu jiných symbolů ani posloupností symbolů
- blok b^k délky k: $c^{k-1}a$, a symbol na vstupu, kontext $c^{k-1} = a_{-k+1}a_{-k+2}\ldots a_{-1} =$ posloupnost bezprostředně předchozích $k-1$ symbolů symbolu a

$=$ permutace bloku b^k na blok obsahující posloupnosti stejných symbolů (viz dále) $\rightarrow$ move-to-front (MTF) kódování permutovaného bloku

Blokové třídění

while načti ze vstupu nejvýše K symbolů jako blok $b^k = b_1^k \in A^+$ **do**
    zapiš na výstup číslo k;
    $i \leftarrow 2$;
    while $i \leq k$ **do**
        $b_i^k \leftarrow$ rotace b_{i-1}^k o 1 symbol doleva;
        $i \leftarrow i + 1$;
    setřiď $b_1^k, \ldots, b_k^k$ lexikograficky;
    $i \leftarrow 1$;
    while $i \leq k$ **do**
        zapiš na výstup poslední symbol b_i^k;
        $i \leftarrow i + 1$;
    zapiš na výstup číslo i, kde $b^k = b_i^k$;

Blokové třídění

Příklad

vstup $barbaraabarboraubaru$,
$A = \{a, b, r, u, o\}, K = 20$

výstup: 20, $rabbbbrruaurbaoaaara$, 9

1	$barbaraabarboraubaru$	$aabarboraubarubarbar$
2	$arbaraabarboraubarub$	$abarboraubarubarbara$
3	$rbaraabarboraubaruba$	$araabarboraubarubarb$
4	$baraabarboraubarubar$	$arbaraabarboraubarub$
5	$araabarboraubarubarb$	$arboraubarubarbaraab$
6	$raabarboraubarubarba$	$arubarbaraabarboraub$
7	$aabarboraubarubarbar$	$aubarubarbaraabarbor$
8	$abarboraubarubarbara$	$baraabarboraubarubar$
9	$barboraubarubarbaraa$	$barbaraabarboraubaru$
10	$arboraubarubarbaraab$	$barboraubarubarbaraa$
11	$rboraubarubarbaraaba$	$barubarbaraabarborau$
12	$boraubarubarbaraabar$	$boraubarubarbaraabar$
13	$oraubarubarbaraabarb$	$oraubarubarbaraabarb$
14	$raubarubarbaraabarbo$	$raabarboraubarubarba$
15	$aubarubarbaraabarbor$	$raubarubarbaraabarbo$
16	$ubarubarbaraabarbora$	$rbaraabarboraubaruba$
17	$barubarbaraabarborau$	$rboraubarubarbaraaba$
18	$arubarbaraabarboraub$	$rubarbaraabarborauba$
19	$rubarbaraabarborauba$	$ubarbaraabarboraubar$
20	$ubarbaraabarboraubar$	$ubarubarbaraabarbora$

Blokové třídění

V lexikograficky setříděných blocích $b_1^k, \ldots, b_k^k$ z předchozího algoritmu:

Kódování

- posloupnost prvních symbolů bloků $b_i^k, i = 1, \ldots, k$ obsahuje posloupnosti stejných symbolů (kvůli setřídění b_i^k) $\Rightarrow$ posloupnost posledních symbolů bloků b_i^k obsahuje posloupnosti stejných symbolů, jestliže je v původním bloku b^k před prvním symbolem bloku b_i^k (lokálně) opakovaně poslední symbol bloku b_i^k (kvůli rotaci o 1 symbol doleva) = častý kontext

Dekódování

- posloupnost prvních symbolů bloků $b_i^k - F_i \in A, i = 1, \ldots, k$ v následujícím algoritmu = lexikograficky setříděná posloupnost posledních symbolů bloků $b_i^k - L_i \in A =$ permutace φ posledních symbolů, $F_{\varphi(i)} = L_i \Leftrightarrow F_j = L_{\varphi^{-1}(j)}$, „stejné za sebe“ (lexikografické třídění)
- v původním bloku b^k je za posledním symbolem L_j bloku $b_j^k, b_j^k \neq b^k$ první symbol F_j bloku $b_j^k \Rightarrow F_{\varphi^{-1}(j)}$ je za $L_{\varphi^{-1}(j)} = F_j$

Blokové třídění

while načti ze vstupu číslo k **do**
    načti ze vstupu k symbolů $L_1, \ldots, L_k \in A$;
    $F_i \leftarrow L_i$ pro $i = 1, \ldots, k$;
    setřiď $F_1, \ldots, F_k$ lexikograficky;
    $a \leftarrow F_1$;
    $i_F(a) \leftarrow 1$;
    $i \leftarrow 2$;
    while $i \leq k$ **do**
        if $F_i \neq a$ **then**
            $a \leftarrow F_i$;
            $i_F(a) \leftarrow i$;
        $i \leftarrow i + 1$;
    // $i_F(a) = 1 + \sum_{b \in A} n_b, n_b =$ `počet stejných` b `před` a `v` $F_1, \ldots, F_k$
    $i \leftarrow 1$;
    while $i \leq k$ **do**
        $\varphi^{-1}(i_F(L_i)) \leftarrow i$;
        $i_F(L_i) \leftarrow i_F(L_i) + 1$;
        $i \leftarrow i + 1$;
    načti ze vstupu číslo j;
    $i \leftarrow 1$;
    while $i \leq k$ **do**
        zapiš na výstup symbol F_j;
        $j \leftarrow \varphi^{-1}(j)$;
        $i \leftarrow i + 1$;

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup:

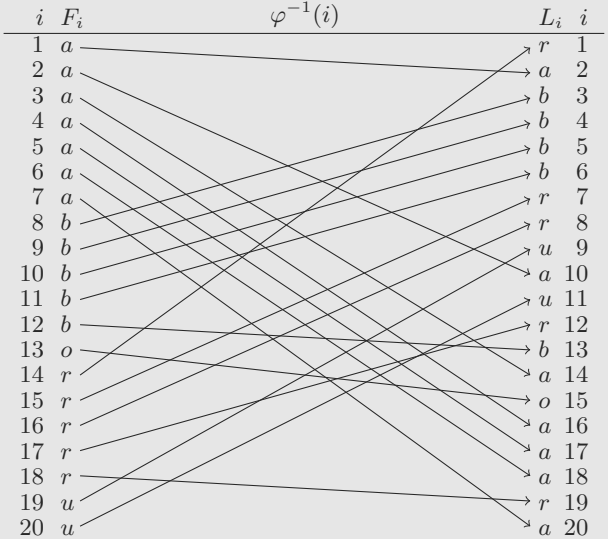

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: b

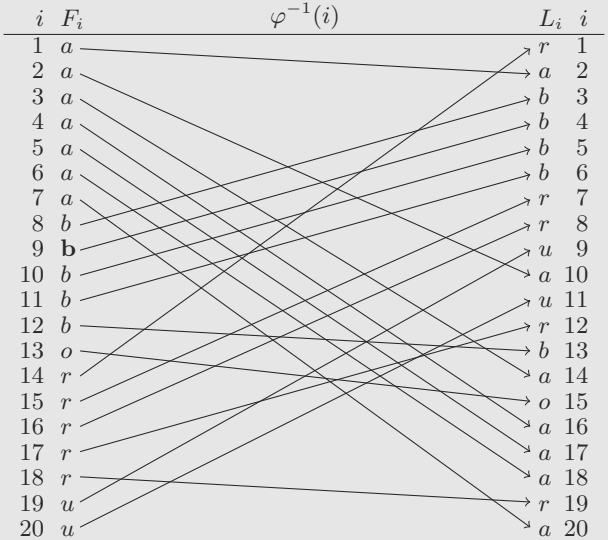

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: ba

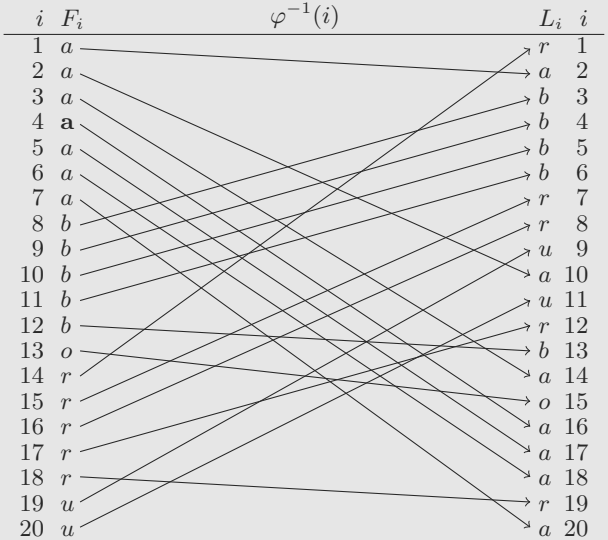

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: bar

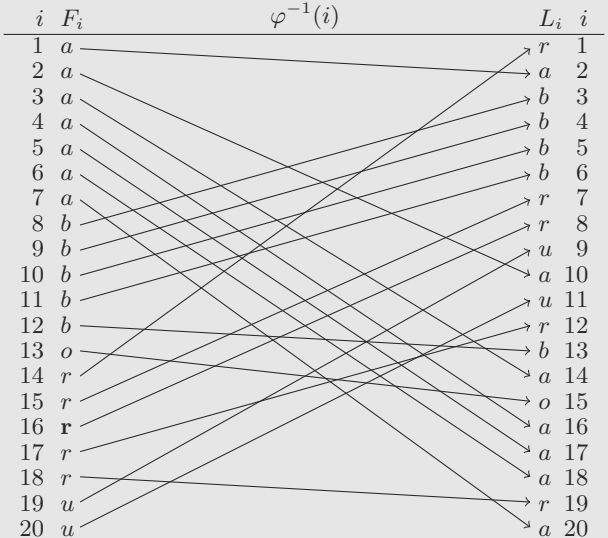

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barb$

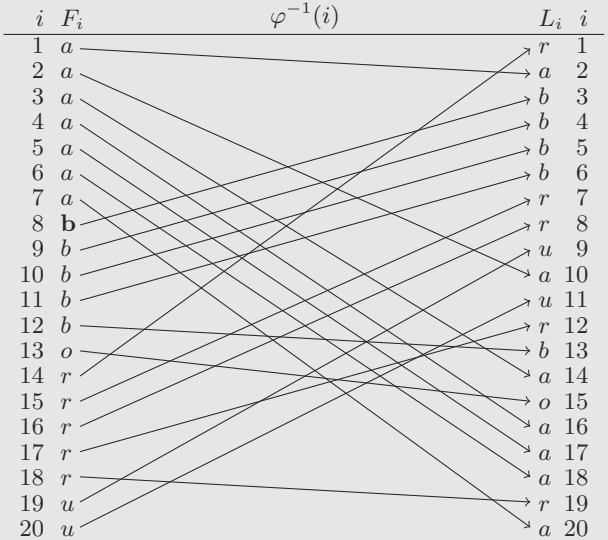

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barba$

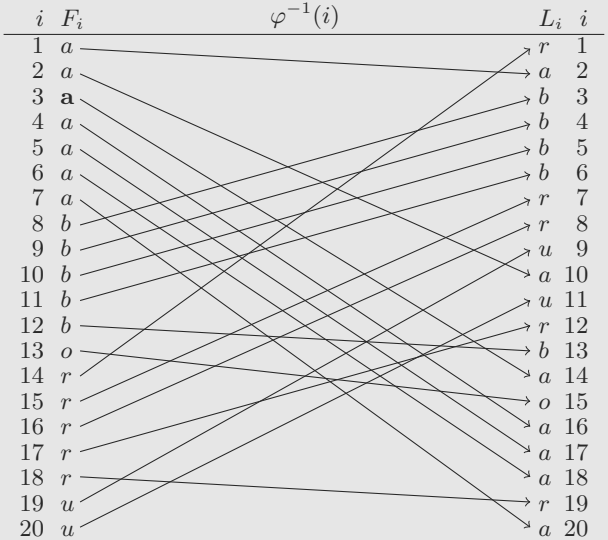

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbar$

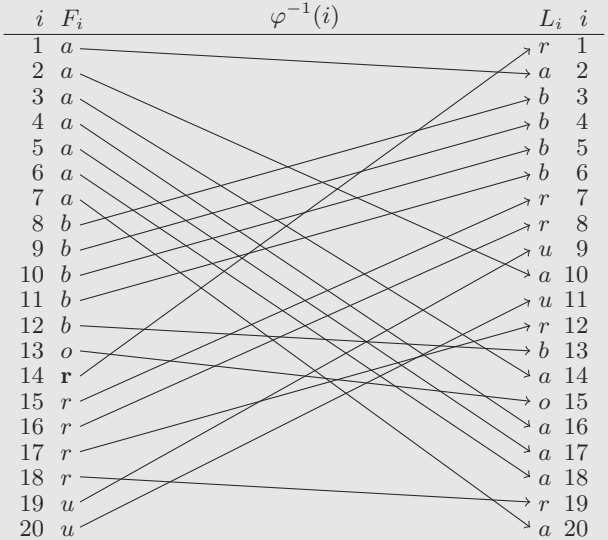

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbara$

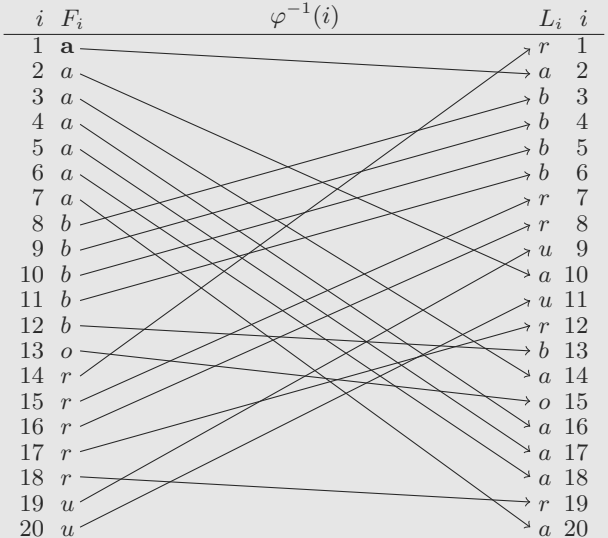

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraa$

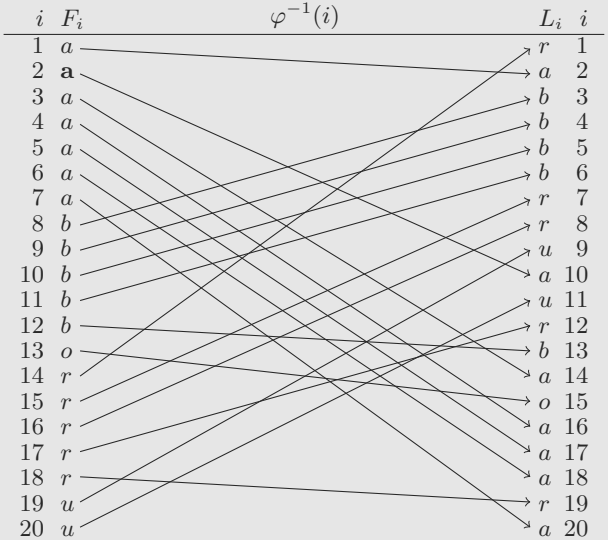

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraab$

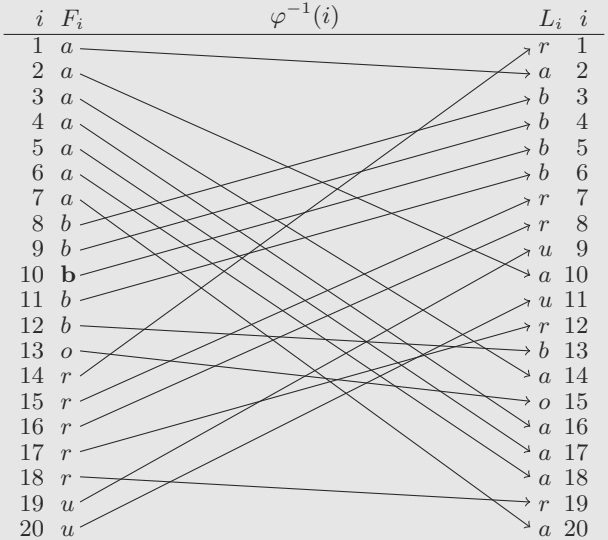

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraaba$

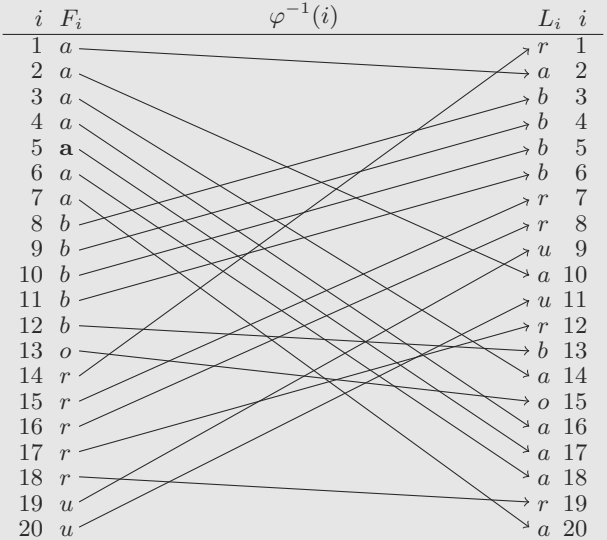

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabar$

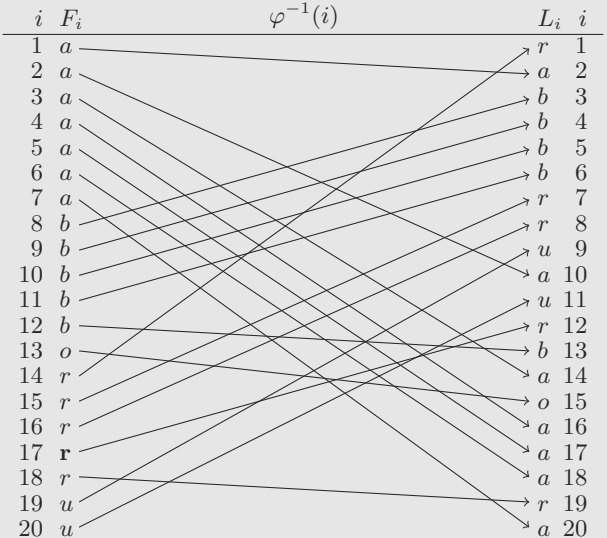

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarb$

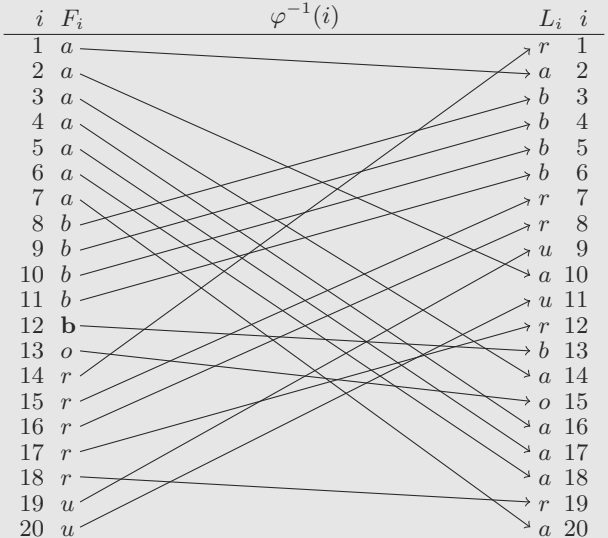

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarbo$

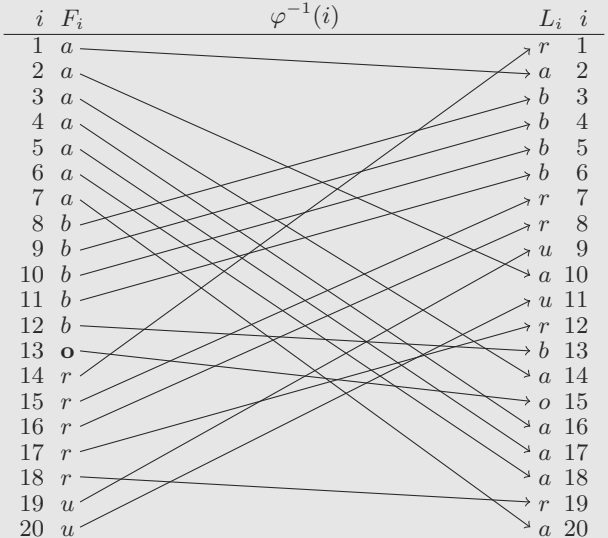

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarbor$

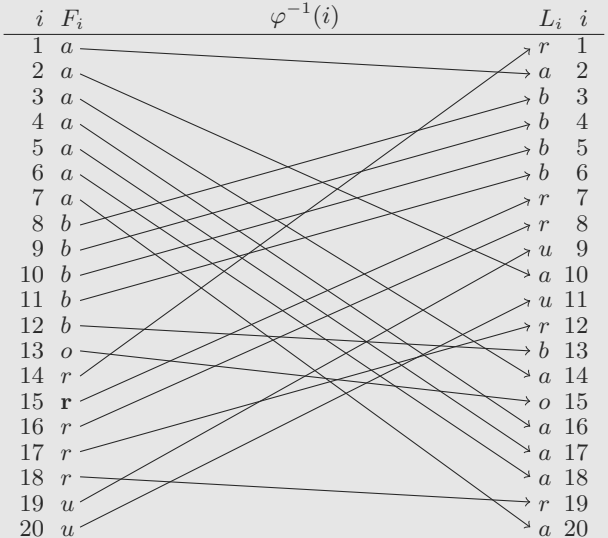

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarbora$

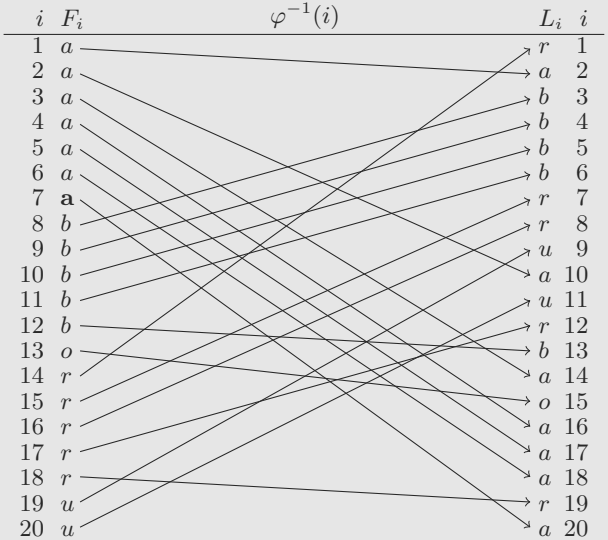

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarborau$

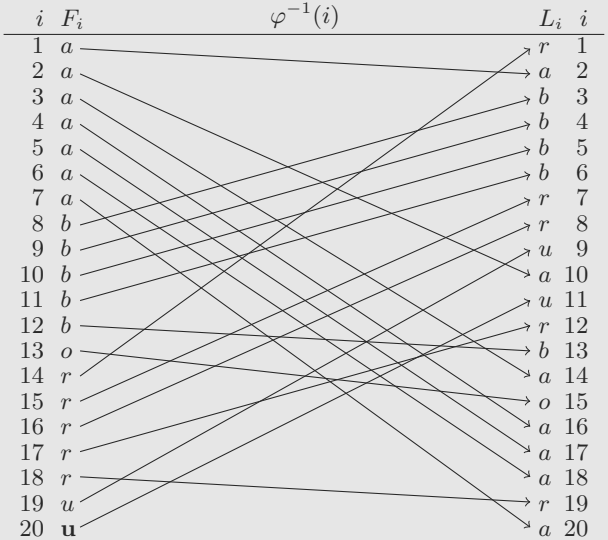

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarboraub$

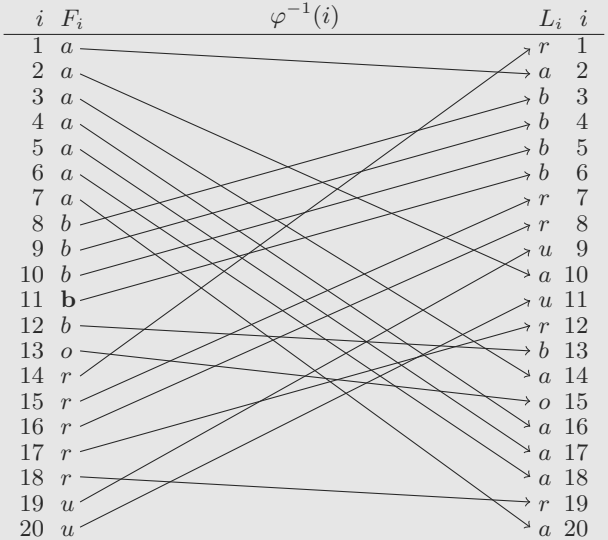

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarborauba$

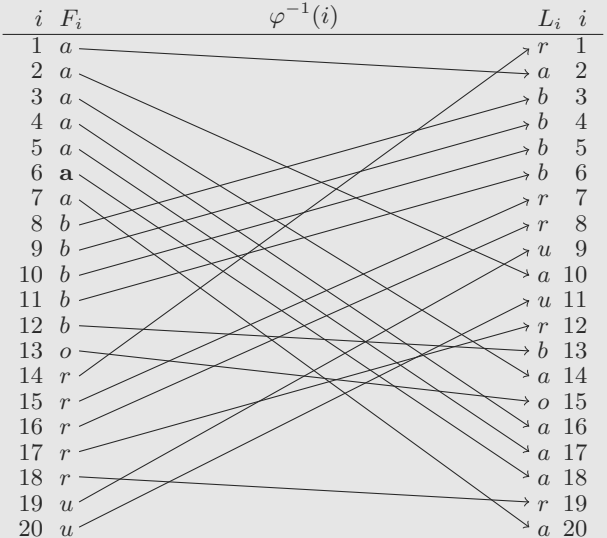

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarboraubar$

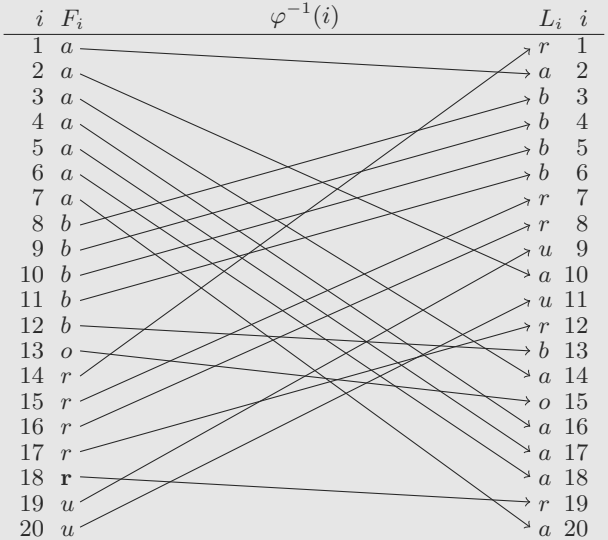

Blokové třídění

Příklad

vstup: 20, $rabbbbrruaurbaoaaara$, 9

$i_F(a) = 1$, $i_F(b) = 8$, $i_F(o) = 13$, $i_F(r) = 14$, $i_F(u) = 19$

výstup: $barbaraabarboraubaru$

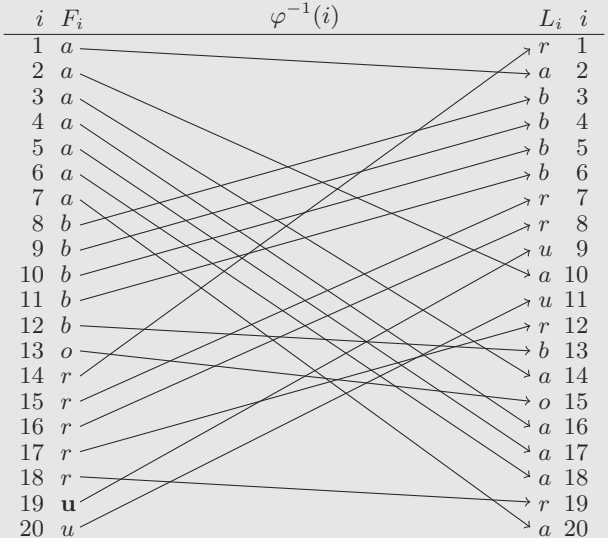

Blokové třídění

Implementace

- maximální délka K bloku až statisíce symbolů (bytů)
- kódování pouze s původním blokem b^k – b_i^k ukazatele na první symbol bloku b_i^k v b^k
- dekódování pouze s posledními symboly $L_i \in A$ bloků $b_i^k, i = 1, \ldots, k$
- move-to-front (MTF) kódování permutovaného bloku následované run-length kódováním (RLE) a statistickým kódováním (Huffmanovým nebo aritmetickým)