POUŽITÍ BURROWS-WHEELEROVY TRANSFORMACE

- moderní bezeztrátové kompresní algoritmy
- BWT: přeuspořádání symbolů v bloku -> sledy

Blok	`mississippimississippimississippi`
BWT	`pppssssssmmmiiipppiiissssssiiiiii`

- Kompresní algoritmus (BWC)

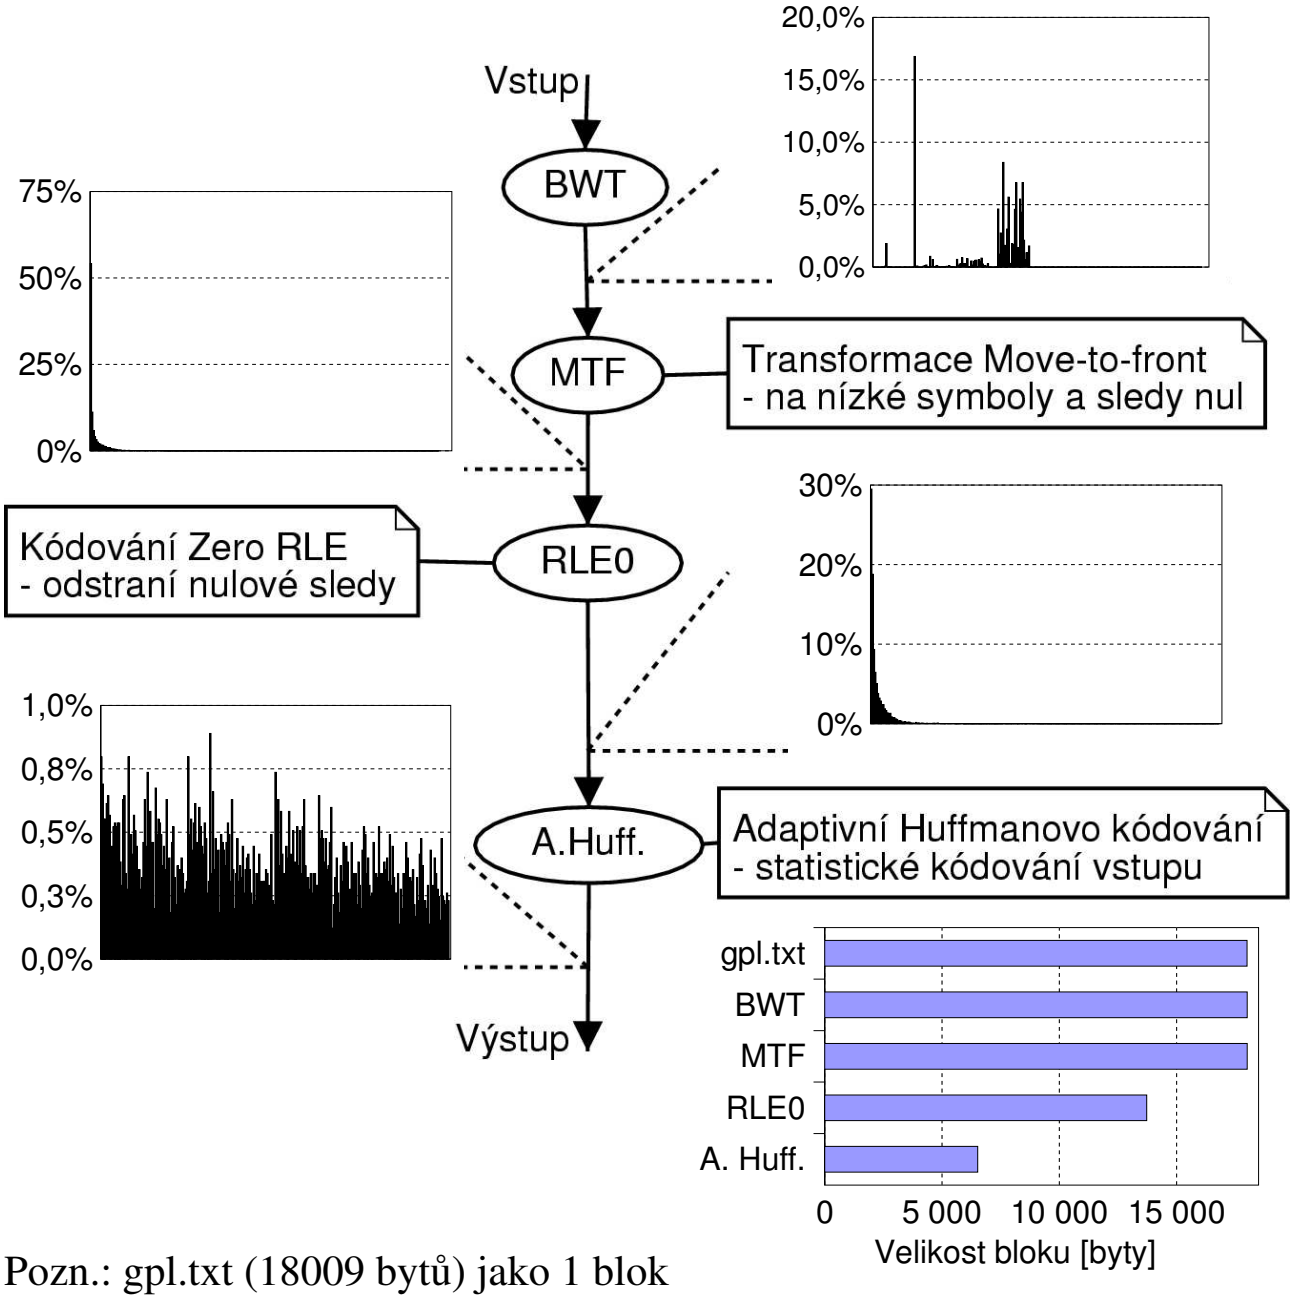

Pozn.: gpl.txt (18009 bytů) jako 1 blok

BURROWS-WHEELEROVA TRANSFORMACE

Kompresní transformace

1. Cyklické rotace bloku o 1 symbol vlevo -> matice *N* x *N*
2. Vzestupné seřazení řádků matice
3. BWT = poslední sloupec (*L*) + index (*I*) původního řádku

```
                          F     L
                0 KAPKA   4 AKAPK 0
                1 APKAK   1 APKAK 1
KAPKA -> 2 PKAKA -> 3 KAKAP 2 -> KKPAA x 3
                3 KAKAP   0 KAPKA 3
                4 AKAPK   2 PKAKA 4
```

Problém: bloky $\approx 10^6$ symbolů, nejhorší časová složitost $O(n^2)$

Dekompresní transformace

- Obnovení *I*-tého řádku matice, *F* cyklicky následuje za *L*
- *n*-tý výskyt symbolu v *m*-tém sloupci = *n*-tý v $m \pm 1$

1. Vytvoření *F* (první sloupec) seřazením *L* (stabilně!)
   resp. seřazením ukazatelů (transformační vektor *R*),
   tj. platí: *F[n] = L[R[n]]*

```
                    0 1 2 3 4  I        I
KKPAA x 3 -> KKPAA  L
             34012  R
           ( AAKKP  F )
```

2. Jednoduchý cyklus (v *R[n]* je index následníka v *F*)

K_3 x 1 -> KA_1 x 4 -> KAP_4 x 2 -> $KAPK_2$ x 0 -> $KAPKA_0$

TRANSFORMACE MOVE-TO-FRONT

- Seznam symbolů abecedy, frekventované na začátku
- Kódování pozice symbolu + přesun na začátek

Krok	Vstup	Seznam	Výstup
1	**K**KPAA	**K**PA	**0**
2	**K**PAA	**K**PA	0**0**
3	**P**AA	K**P**A	00**1**
4	**A**A	PK**A**	001**2**
5	**A**	**A**PK	0012**0**

- Charakteristika výstupu (v návaznosti na BWT)
  - omezené spektrum symbolů
  - sled délky *n* -> sled *n-1* nul

Problém: počáteční konfigurace seznamu -> celá ASCII

KÓDOVÁNÍ ZERO RLE

- Efektivní kódování pouze jednoho typu sledů (nul)
- Symbol + počet následujících (0 pro žádný)
  tj. max. délka sledu pro ASCII: $1+(2^8-1) = 256$

Vstup	111**00000**222**0**333
Výstup	111**04**222**00**333

ADAPTIVNÍ HUFFMANOVO KÓDOVÁNÍ

- Huffmanův strom jen pro právě zpracovanou část vstupu (na začátku je strom „prázdný“)
- Pouze 1 průchod a respektování lokálních změn četností
- Jak (de)kódovat nové symboly?

  Kód ESCAPE – speciální uzel stromu (ESC), předchází nový symbol
- Jak dekódovat „zarovnaný“ konec vstupu?

  Kód END_OF_STREAM (uzel EOF)
- Hlavní problém
  - efektivní aktualizace (`update`)
    při zachování Huffmanova stromu
    + přetečení ohodnocení kořenu

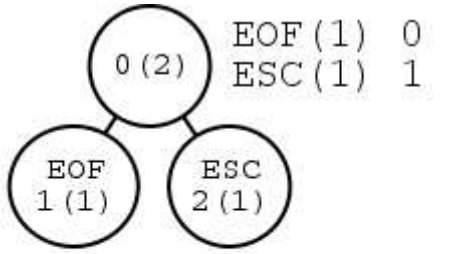

Vstup: 'm'
Výstup: '1m' + aktualizace stromu

Model kódování

```
init();
while((symbol = input.get())
      != END_OF_INPUT) {
   encode(symbol, output);
   update(symbol);
}
encode(END_OF_STREAM, output);
```

Model dekódování

```
init();
while((symbol = decode(input))
      != END_OF_STREAM) {
   output.put(symbol);
   update(symbol);
}
```

EXPERIMENTÁLNÍ VÝSLEDKY

- Srovnání kompresních programů (BWC vs. ostatní)

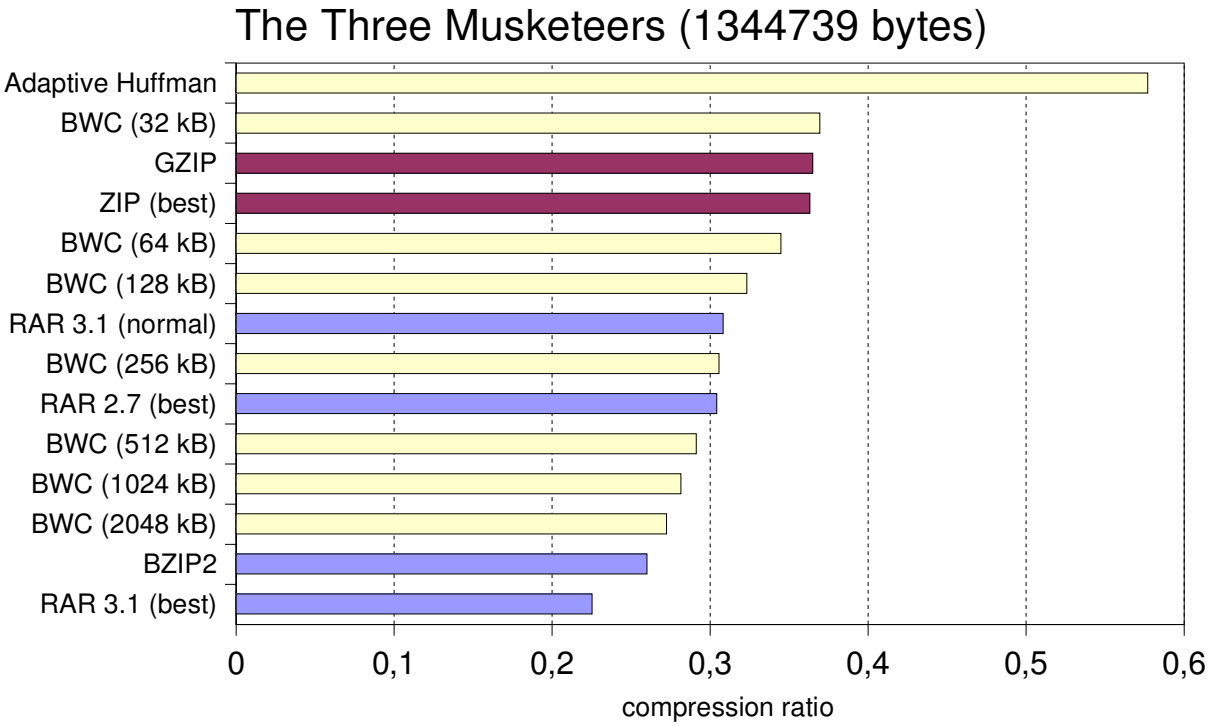

- BWT (BWC, BZIP2) vs. slovníkové metody (GZIP)