Kompresní algoritmy

Komprese

Cíl komprese: redukovat objem dat za účelem

- přenosu dat
- archivace dat
- vytvoření distribuce sw
- ochrany před viry

Kvalita komprese:

- rychlost komprese
- symetrie/asymetrie kompresního algoritmu
  - Symetrické algoritmy – stejný čas potřebný pro kompresy i dekompresi
  - Asymetrické algoritmy –čas potřebný pro kompresi a dekompresi se liší
- kompresní poměr = poměr objemu komprimovaných dat k objemu dat nekomprimovaných

Komprese:

- bezztrátová - po kódování a dekódování je výsledek 100% shodný,
  - nižší kompresní poměr
  - požívají s výhradně pro kompresi textovů a v případech, kdy nelze připustit ztrátu informace
- ztrátová - po kódování a dekódování dochází ke ztrátě
  - obvykle vyšší kompresní poměr než bezztrátové
  - lze použít pouze v případech kdy ztráta je akceptovatelná (komprese obrazů, zvuku

Metody komprese:

- jednoduché – založené na kódování opakujících se posloupností znaků (RLE)
- statistické – založené na četnosti výskytu znaků v komprimovaném souboru (Huffmanovo kódování, Aritmetické kódování)
- slovníkové – založené na kodování všech vyskytujících se posloupností (LZW)
- transformační – založené na ortogonálních popř. jiných transformacích (JPEG, waveletová komprese, fraktálová komprese)

Jednoduché metody komprese

RLE (Run Length Encoding) – kódování délkou běhu

- **Charakteristika**: bezztrátová metoda
- **Použití:** zřídka pro kompresi textů, častěji pro obrazovou informaci
- **Princip:** opakující se symboly se kódují dvojicí
  (počet_opakování , symbol)

Kódování délky se provádí:

- přímo – u každého znaku je udán počet opakování

  Př. Vstup: AAAABBCDDDDABD
  Výstup: 4A2B1C4D1A1B1D

  Nevýhoda: pokud se znaky neopakují často nedochází ke kompresi, ale naopak k prodloužení kódovaného souboru

- pomocí *escape* sekvencí – kódují se pouze opakující se sekvence delší než 3 znaky, kratší sekvence se zapisují přímo do výstupního souboru

  Př. Vstup: AAAABBCDDDDABD
  Výstup: #4ABBC#4DABD

  Výhoda: neprodlužuje soubor, kde není co komprimovat to zůstane v původní podobě

Pozor !!! z množiny znaků je nutné vyčlenit symbol, který se nevyskytuje v komprimovaném souboru. Dále může nastat problém pokud je opakující se sekvence delší než 255 znaků (pokud kódujeme délku běhu na 8 bitech). Řešení závisí na konkrétní aplikaci

Použití RLE : např. obrazový formát BMP

Příklad použití RLE pro bitové obrazy

Natural encoding: 51 × 19 + 6 = 975 bits.
Run-length encoding: 63 × 6 + 6 = 384 bits.

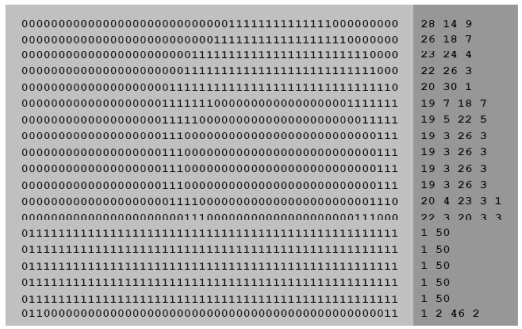

raster of letter 'q' lying on its side RLE

Slovníková metoda komprese

LZW (Lempel-Ziv-Welch) metoda

Princip:

- vyhledávání opakujících se posloupností znaků, ukládání těchto posloupností do slovníku pro další použití a přiřazení jednoznakového kódu těmto posloupnostem.
- jednoprůchodová metoda (nevyžaduje předběžnou analýzu souboru)
- Kódované znaky musí mít délku (počet bitů) větší než délka původních znaků (např. pro ASCII znaky (8 bitů) se obvykle používá nová délka znaků 12 bitů popř. větší.)
- Při průchodu komprimovaným souborem se vytváří slovník (počet položek slovníku odpovídá hodnotě $2^{(\text{počet bitů nového kódu})}$, kde prvních $2^{(\text{počet bitů původního kódu})}$ položek jsou znaky původní abecedy a zbývající položky tvoří posloupnosti znaků obsažené v komprimovaném souboru.

Algoritmus komprese a vytvoření slovníku

```
S := přečti znak ze vstupu;

while (jsou další znaky na vstupu) do
begin
 C := přečti znak ze vstupu;
 if S+C je v kódovací tabulce then
   S := S+C
 else begin
     zapiš na výstup kód pro S
        přidej do kódovací tabulky (S+C)
        S := C
     end;
end;
zapiš na výstup kód pro S;
```

Výsledný výstupní řetězec:

65 66 67 256 258 257 68 259

Příklad: Komprese řetězce ABCABCABCDABC

Postup kódování

S (prefix)	C (suffix)	výstup (kód)
A	B	A(65)
B	C	B(66)
C	A	C(67)
A	B	—
AB	C	AB(256)
C	A	—
CA	B	CA(258)
B	C	—
BC	D	BC(257)
D	A	D(68)
A	B	—
AB	C	—
ABC	—	ABC(259)

kód	posloupnost
0..255	jednotlivé znaky
256	AB
257	BC
258	CA
259	ABC
260	CAB
261	BCD
262	DA

Algoritmus dekomprese a vytvoření slovníku

```
přečti OLD_CODE;
zapiš OLD_CODE na výstup;
while (na vstupu jsou další kódy) do
begin
  přečti NEW_CODE;
  if NEW_CODE není v kódovací tabulce then
    begin
      S := posloupnost zakódovaná kódem OLD_CODE;
      S := S+C;
    end
  else S := posloupnost zakódovaná kódem NEW_CODE;

  zapiš S na výstup;
  C := první znak S;
  přidej do kódovací tabulky (OLD_CODE+C);
  OLD_CODE := NEW_CODE;
end;
```

Vstupní řetězec:

65 66 67 256 258 257 68 259

OLD_CODE	NEW_CODE	S	C	Výstup
A(65)				A
A(65)	B(66)	B	B	B
B(66)	C(67)	C	C	C
C(67)	AB(256)	AB	A	AB
AB(256)	CA(258)	CA	C	CA
CA(258)	BC(257)	BC	B	BC
BC(257)	D(68)	D	D	D
D(68)	ABC(259)	ABC	A	ABC

Výstupní řetězec:

ABCABCABCDABC

Test existence NEW_CODE možná vypadá zbytečně, ale existují případy ve kterých to bez tohoto testu nefunguje, např. u řetězce ABABABAB !!!!

Použití : často používaná metoda u textových i grafických souborů (např. PKZIP, ARJ, ZIP,TIFF, GIF)

Statistické metody komprese

- Huffmanovo kódování
- Aritmetické kódování

Huffmanovo kódování

- algoritmus navržen v Davidem Huffmanem v roce 1952
- využívá optimálního (nejkratšího) prefixového kódu (kód žádného znaku není prefixem jiného znaku).
- kódové symboly mají proměnnou délku

Princip: Metoda je založená na stanovení četnosti výskytů jednotlivých znaků v kódovaném souboru a kódování znaků s největší četností slovem s nejkratší délkou.

Algoritmus kódování:

1. Zjištění četnosti jednotlivých znaků v kódovaném souboru
2. Vytvoření binárního stromu (Huffmanova kódu jednotlivých znaků)
   seřadíme posloupnost postupně zleva doprava doprava podle:
   - četnosti
   - podstrom bude vlevo před listem, větší podstrom před menším
   - pořadí v abecedě
3. Uložení stromu
4. Nahrazení symbolů jednotlivými kódy (posloupností bitů)

Algoritmus vytvoření stromu

jednotlivé znaky označíme za vrcholy grafu (listy stromu) a dáme je do seznamu S

```
while (S.length>1) {
 v S nalezneme dva vrcholy m, n s nejmenšími počty
   výskytů
 p = new Vrchol;
 p.left = m; p.right = n;
 p.count = m.count + n.count; // count je # výskytů
 S.remove(m, n); S.add(p);
 }
```

S obsahuje kořen stromu
najdeme kódy jednotlivých znaků (při průchodu z kořene do listu kódujeme 0 při kroku vlevo a 1 vpravo)

Příklad : ABRAKADABRA

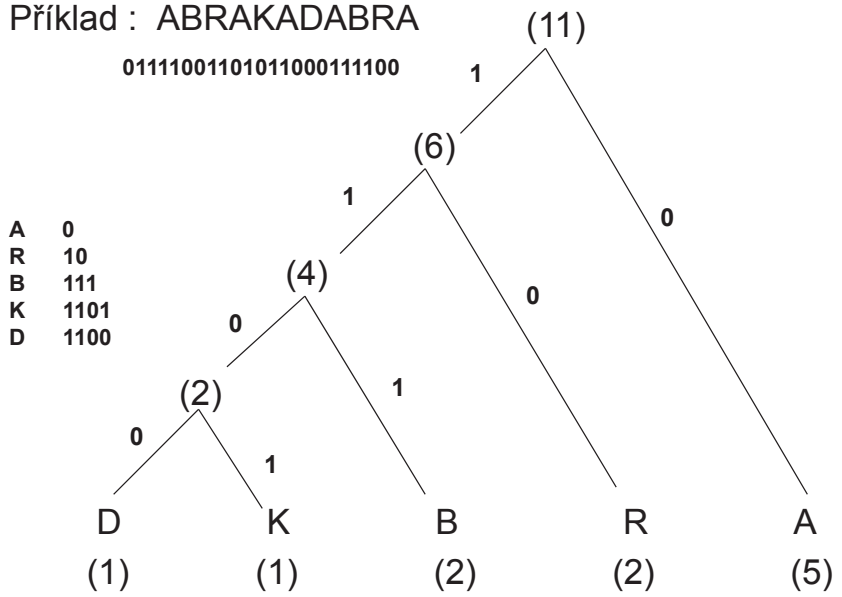

- strom se ukládá na začátek kódované sekvence a přenáší se s komprimovaným souborem. Dekodér si ho nejprve vytvoří dekódovací strom a pak zpracovává vlastní kód.

Struktura stromu (ukládaná a spolu s kódem)

- Stromem se prochází do hloubky. Pro každý uzel se uloží bit 0, pro každý list se uloží bit 1 následovaný osmi bity s kódem listu. Uloženým stromem se při načítání postupuje takto: Jestliže narazíš na bit 0, vytvoř z aktuálního prvku uzel a postup do levého následovníka. Jestliže narazíš na bit 1, načti dalších osm (devět) bitů, ulož je do listu a postup na nejbližší volný prvek napravo. Načítání stromu skončí v momentě, kdy už není žádný volný prvek. Tímto způsobem se vygeneruje strom, kterým se při zpracování dat prochází.

- pro předchozí případ (řetězec ABRAKADABRA):

```
01A001R0001D01K01B
```

Dekomprese

1. Načtení a obnovení stromu, algoritmus je popsán při kompresi X
2. Vlastní dekomprese: Nahrazení kódů původními znaky.

```
v = vrchol stromu
while (!eof(input)) do {
  b = read bit
  if (b==0)
      v = v.left
  else v = v.right
  if (v je list) {
    write v.value // znak reprezentovany tímto listem
      v = vrchol stromu
    }
}
```

Aritmetické kódování

- Statistická metoda

- Kóduje celou zprávu jako jedno kódové slovo (v původní verzi číslo z intervalu [0,1).

Princip : Aritmetické kódování reprezentuje zprávu jako podinterval intervalu <0,1). Na začátku uvažujeme celý tento interval. Jak se zpráva prodlužuje, zpřesňuje se i výsledný interval a jeho horní a dolní mez se k sobě přibližují. Čím je kódovaný znak pravděpodobnější, tím se interval zúží méně a k zápisu delšího (to znamená hrubšího) intervalu stačí méně bitů. Na konec stačí zapsat libovolné číslo z výsledného intervalu.

Algoritmus komprese

1. Zjištění pravděpodobnosti P(i) výskytu jednotlivých znaků ve vstupním souboru
2. Stanovení příslušných kumulativních pravděpodobností K(0)=0, K(i)=K(i-1)+P(i-1) a rozdělení intervalu <0,1) na podintervaly I(i) odpovídající jednotlivým znakům (seřazeným podle abecedy)tak, aby délky těchto intervalů vyjadřovaly pravděpodobnosti příslušných znaků: I(i) = <K(i), K(i+1))
3. Uložení použitých pravděpodobností
4. Vlastní komprese

začínáme s intervalem I=<0,1): označme jeho dolní mez D(I), horni H(I) a délku intervalu L(I)=H(I)-D(I)

```
while (!eof) {
 read(i)
 I = <D(I)+K(i)*L(I), D(I)+K(i+1)*L(I))
}
write(D(I))
```

Příklad kódování

Vstup: **a** $L = 0$
$H = 0 + 0.5 \cdot 1 = 0.5$

b $L = 0 + 0.5(0.5 - 0) = 0.25$
$H = 0 + 0.5(0.5 - 0) + 0.25(0.5 - 0) = 0.375$

a $L = 0.25$
$H = 0.25+0.5 \cdot (0.375-0.25) = 0.3125$

a $L = 0.25$
$H = 0.25+0.5 \cdot (0.3125-0.25) = 0.28125$

b $L = 0.25+0.5 \cdot (0.28125-0.25) = 0.265625$
$H = 0.25+0.5 \cdot (0.28125-0.25)+0.25 \cdot (0.28125-0.25) = 0.2734375$

c $L = 0.265625+0.5 \cdot (0.273437c-0.265625)+0.25 \cdot (0.2734375-0.265625) = 0.271484375$
$H = 0.265625+0.5 \cdot (0.2734375-0.265625)+0.25 \cdot (0.2734375-0.265625)+0.125 \cdot 0.25 (0.2734375 0.265625)=0.2724609375$

Atd.

Příklad kódování

P(a)=0.5, P(b)=0.25, P(c)=0.125, P(d)=0.125

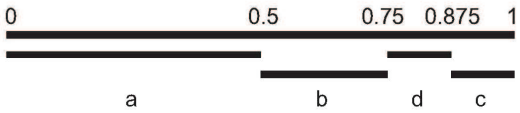

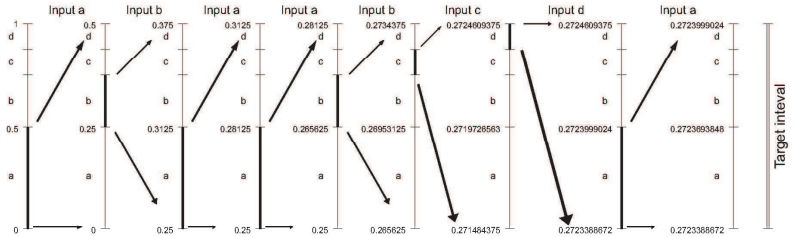

Dekomprese

1. Rekonstrukce použitých pravděpodobností
2. Vlastní dekomprese

```
read(X) přečteme uložené reálné číslo
while (není obnovena celá zpráva) {
  najdeme i, aby X bylo v [K(i), K(i+1))
  write(i)
  X=(X-K(i))/P(i)
 }
```

Ztrátové komprese

- JPEG
- Waveletová komprese
- Fraktálová komprese

JPEG (Joint Photographic Experts Group)

- v současné době patří mezi nejvíce používané komprese u obrázků
- je vhodná pro komprimaci fotek, nevhodná pro např. technické výkresy (čarové výkresy) – dochází k viditelnému rozmazání

Princip:

- části obrazu se transformují do frekvenční oblasti (výsledkem je matice „frekvenčních“ koeficientů
- z matice koeficientů se odstraní koeficienty odpovídající vyšším frekvencím (rychlejší změny jasu – např. hrany v obraze)
- zbývající koeficienty se vhodným způsobem zkomprimují

Blokové schéma Jpeg komprese (kodér)

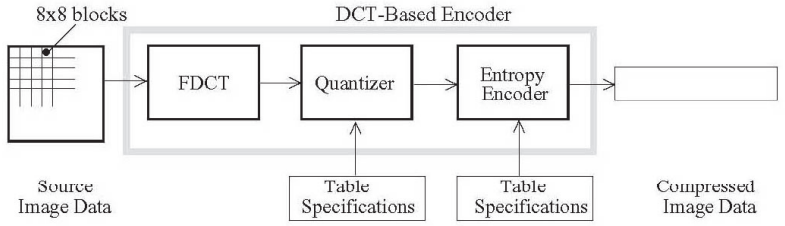

Blokové schéma Jpeg komprese (dekodér)

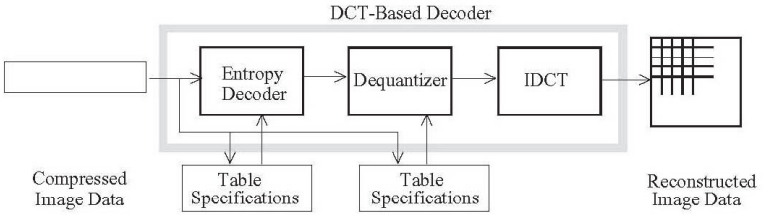

DCT – Diskrétní kosinová transformace

- transformuje kódovanou oblast do frekvenční oblasti
- je bezztrátová a existuje k ní inverzní transformace

Postup:

1. Zdrojový obraz se nejprve rozdělí na bloky 8x8 pixelů
2. Hodnoty jasu v každém bloku se nejprve transformují z intervalu $[0,2^{p}-1]$ na interval $[2^{p-1},2^{p-1}-1]$
3. Provede se diskrétní kosinová transformace podle vztahu:

$$F(u,v)=\frac{1}{4}C(u)\cdot C(v)\cdot\left[\sum_{x=0}^{7}\sum_{y=0}^{7}f(x,y)\cdot\cos\frac{(2x+1)u\pi}{16}\cos\frac{(2y+1)v\pi}{16}\right] \qquad (DCT)$$

$$f(x,y)=\frac{1}{4}\left[\sum_{u=0}^{7}\sum_{v=0}^{7}C(u)\cdot C(v)\cdot F(u,v)\cdot\cos\frac{(2x+1)u\pi}{16}\cos\frac{(2y+1)v\pi}{16}\right] \qquad (IDCT)$$

$$C(u),C(v)=1/\sqrt{2},\ pro\ u,v=0$$

$$C(u),C(v)=1,\qquad pro\ u,v$$

Kvantizace / dekvantizace

- V tomto kroku se každý z 64 koeficientů DCT (IDCT] vydělí (vynásobí) odpovídajícím prvkem kvantizační matice a zaokrouhlí na nejbližší celé číslo. V tomto kroku dochází ke ztrátě informace !!!!!

kvantizace

$$F^{Q}(u,v)=Integer\left(\frac{F(u,v)}{Q(u,v)}\right)$$

dekvantizace

$$F^{Q'}(u,v)=F^{Q}(u,v)\cdot Q(u,v)$$

$Q_{50}=$

16	11	10	16	24	40	51	61
12	12	14	19	26	58	60	55
14	13	16	24	40	57	69	56
14	17	22	29	51	87	80	62
18	22	37	56	68	109	103	77
24	35	55	64	81	104	113	92
49	64	78	87	103	121	120	101
72	92	95	98	112	100	103	99

$$Q_q=\frac{Q_{50}(100-q)}{50}\qquad pro\ \ q\in(50,100)$$

$$Q_q=\frac{50\cdot Q_{50}}{q}\qquad pro\ \ q\in(0,50)$$

Kódování DCT koeficientů

- Koeficienty DCT se obvykle kódují pomocí statistických metod (Huffmann, aritmetické kódování)
- Koeficient v pozici (0,0) je označen jako DC koeficient (stejnosměrná složka), ostatní se označují jako AC koeficienty
- Vzhledem k tomu že DC koeficienty sousedních bloků jsou obvykle silně korelované (tj. střední hodnota jasů sousedních bloků je podobná) kódují se DC koeficienty odděleně od AC koeficientů
- kódování DC koeficientů – diference hodnot sousedních bloků (DC prvního bloku se kóduje jako přímá hodnota) - výsledná hodnota se kóduje jako dvojice

(velikost) (amplituda)

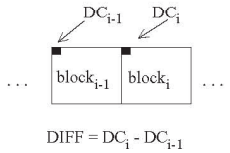

SIZE	AMPLITUDE
1	-1,1
2	-3,-2,2,3
3	-7..-4,4..7
4	-15..-8,8..15
5	-31..-16,16..31
6	-63..-32,32..63
7	-127..-64,64..127
8	-255..-128,128..255
9	-511..-256,256..511
10	-1023..-512,512..1023

- Kódování AC koeficientů – délkou běhu - nejprve se koeficienty uspořádají podle následujícího obrázku pak se kódují jako trojice

(RL,velikost) (amplituda)

kde RL je počet nul které jsou před kódovanou hodnotou, velikost a amplituda jsou shodné jako při kódování DC koeficientů

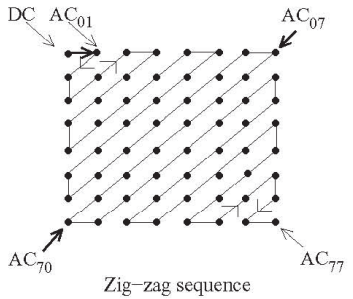

Příklad kódování bloku obrazu

139	144	149	153	155	155	155	155
144	151	153	156	159	156	156	156
150	155	160	163	158	156	156	156
159	161	162	160	160	159	159	159
159	160	161	162	162	155	155	155
161	161	161	161	160	157	157	157
162	162	161	163	162	157	157	157
162	162	161	161	163	158	158	158

(a) source image samples

235.6	-1.0	-12.1	-5.2	2.1	-1.7	-2.7	1.3
-22.6	-17.5	-6.2	-3.2	-2.9	-0.1	0.4	-1.2
-10.9	-9.3	-1.6	1.5	0.2	-0.9	-0.6	-0.1
-7.1	-1.9	0.2	1.5	0.9	-0.1	0.0	0.3
-0.6	-0.8	1.5	1.6	-0.1	-0.7	0.6	1.3
1.8	-0.2	1.6	-0.3	-0.8	1.5	1.0	-1.0
-1.3	-0.4	-0.3	-1.5	-0.5	1.7	1.1	-0.8
-2.6	1.6	-3.8	-1.8	1.9	1.2	-0.6	-0.4

(b) forward DCT coefficients

16	11	10	16	24	40	51	61
12	12	14	19	26	58	60	55
14	13	16	24	40	57	69	56
14	17	22	29	51	87	80	62
18	22	37	56	68	109	103	77
24	35	55	64	81	104	113	92
49	64	78	87	103	121	120	101
72	92	95	98	112	100	103	99

(c) quantization table

15	0	-1	0	0	0	0	0
-2	-1	0	0	0	0	0	0
-1	-1	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

(d) normalized quantized coefficients

240	0	-10	0	0	0	0	0
-24	-12	0	0	0	0	0	0
-14	-13	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

(e) denormalized quantized coefficients

144	146	149	152	154	156	156	156
148	150	152	154	156	156	156	156
155	156	157	158	158	157	156	155
160	161	161	162	161	159	157	155
163	163	164	163	162	160	158	156
163	164	164	164	162	160	158	157
160	161	162	162	162	161	159	158
158	159	161	161	162	161	159	158

(f) reconstructed image samples

Příklad kódování bloku obrazu

15	0	-1	0	0	0	0	0
-2	-1	0	0	0	0	0	0
-1	-1	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

Předpoklad: předchozí blok měl kvantizovaného DC koeficientu +12

Poslopnost symbolů procelý obraz je pak možné kódovat Huffmanovým kódem

Posloupnost symbolů, které kódují blok je:

…….. **(2)(3), (1,2)(-2), (0,1)(-1), (0,1)(-1), (0,1)(-1), (0,0)** ……

Konec bloku

Waveletová komprese

Charakteristika:

- ztrátová komprese
- podobný princip jako u JPEG komprese
- využívá lineární transformaci (waveletovou transformaci)
- obvykle dosahuje vyšších kompresních poměrů

Použití:

- FBI – komprese otisků prstů
- JPEG 2000

JPEG 2000

- cílem bylo navrhnout nový obrazový standard, který překonává některé nedostatky které byly u JPEG komprese
- vhodný pro rozdílné typy statických obrazů (binární, šedotónový, barevný) s rozdílnými charakteristikami (scenérie, technické výkresy, družicové snímky)
- vhodný pro rozdílné účely – přenos obrazů, archivace
- kódování JPEG 2000 může být ztrátové nebo bezztrátové

Blokové schéma kodovacího procesu

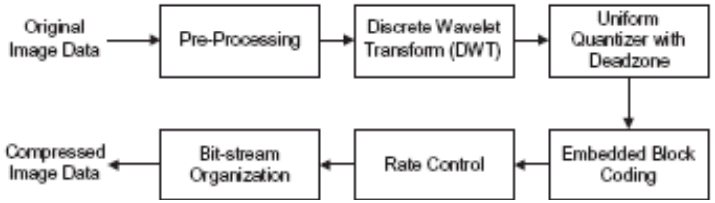

- barevná transformace z RGB do Y,C_r,C_b

$$\begin{bmatrix} Y \\ C_r \\ C_b \end{bmatrix} = \begin{bmatrix} 0.299 & 0.586 & 0.114 \\ -0.169 & -0.331 & 0.500 \\ 0.500 & -0.419 & -0.081 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

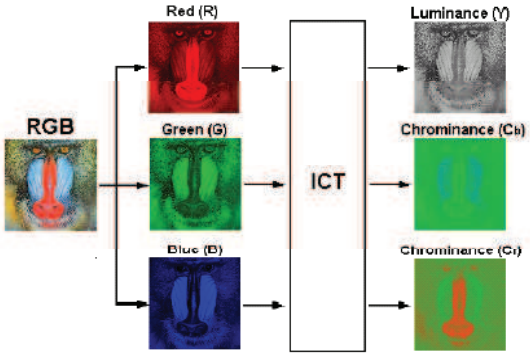

Předzpracování

tři kroky předzpracování:

- **rozdělení obrazu na bloky** – bloky se nepřekrývají, jsou stejné velikosti, každý blok je komprimován samostatně s vlastními parametry komprese

- **normalizace úrovní** – jelikož JPEG2000 používá filtr typu horní propust očekává se že rozsah vstupních hodnot je rozložen okolo nuly (je-li rozsah vstupu na B bitech bude vstup po normalizaci v rozsahu $-2^{B-1} \le x \le 2^{B-1}$

- **barevná transformace** – většinou jsou komprimovány barevné obrazy v RGB reprezentaci, ta je ale nevhodná pro ztrátovou kompresy (dochází k posuvu barev) používá se jiný barevný model (Y,C_r,C_b)

Diskrétní waveletová transformace

JPEG 2000 je založen na diskrétní waveletové dekompozici DWT

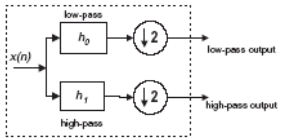

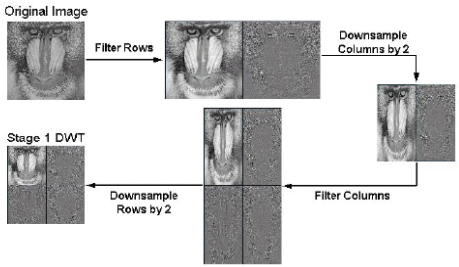

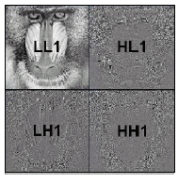

1. úroveň

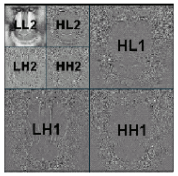

2. úroveň

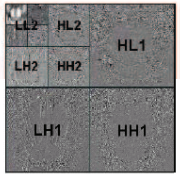

3. úroveň

- **počet úrovní dekompozice závisí na implementaci**

Systém kódování bloků

- každý dekompoziční blok je rozdělen do nepřekrývajících se menších bloků (64x64 nebo 32x32 koeficientů)

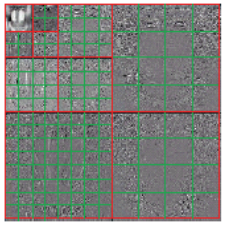

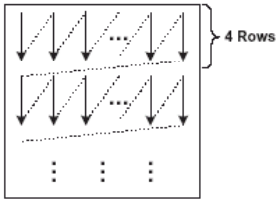

Kvantizace

waveletové koeficienty z každé úrovně dekompozice jsou kvantizovány podle vztahu

$$q = \mathrm{sign}(y)\left\lfloor \frac{|y|}{\Delta_b} \right\rfloor$$

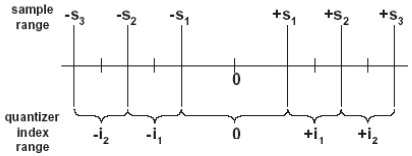

výsledkem kvantizace je náhrada hodnoty každého koeficientu kvantizačním indexem

$$\text{Quantizer Index} = -\left\lfloor \frac{21.82}{10} \right\rfloor = -2$$