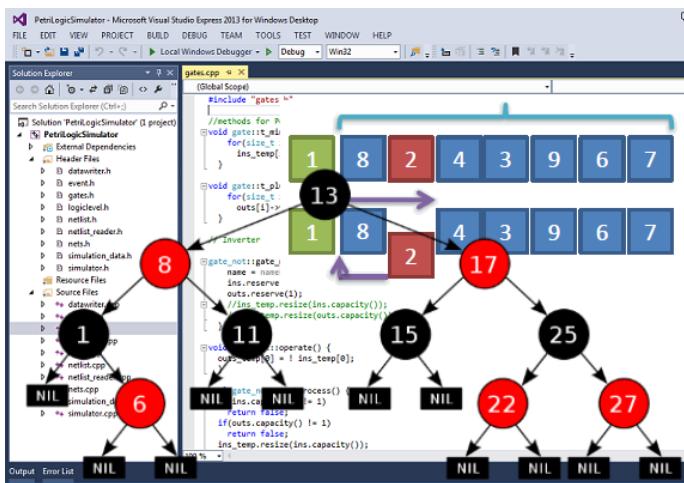




Теория алгоритмов



Лекция 5

Основы алгоритмов компрессии данных

Виды сжатия

Виды алгоритмов сжатия

Без потерь

После декомпрессии или
обработки
последовательность бит в
точности соответствует
исходным данным



С потерями

После декомпрессии или обработки
последовательность бит **не**
соответствует исходным данным, но
это не является принципиальным
моментом с точки зрения дальнейшей
работы

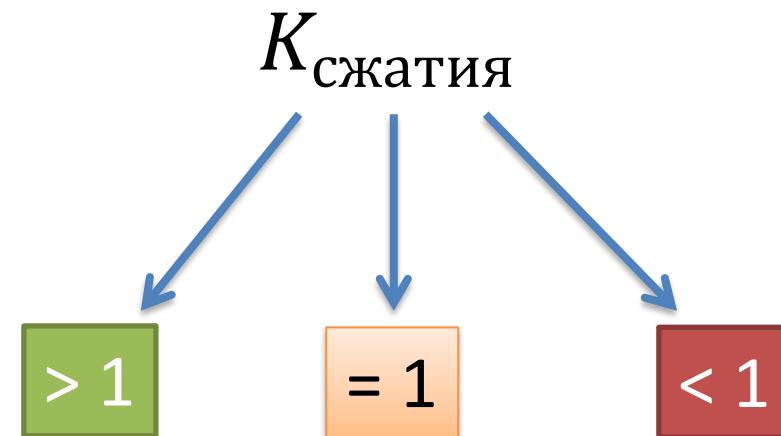


Коэффициент сжатия

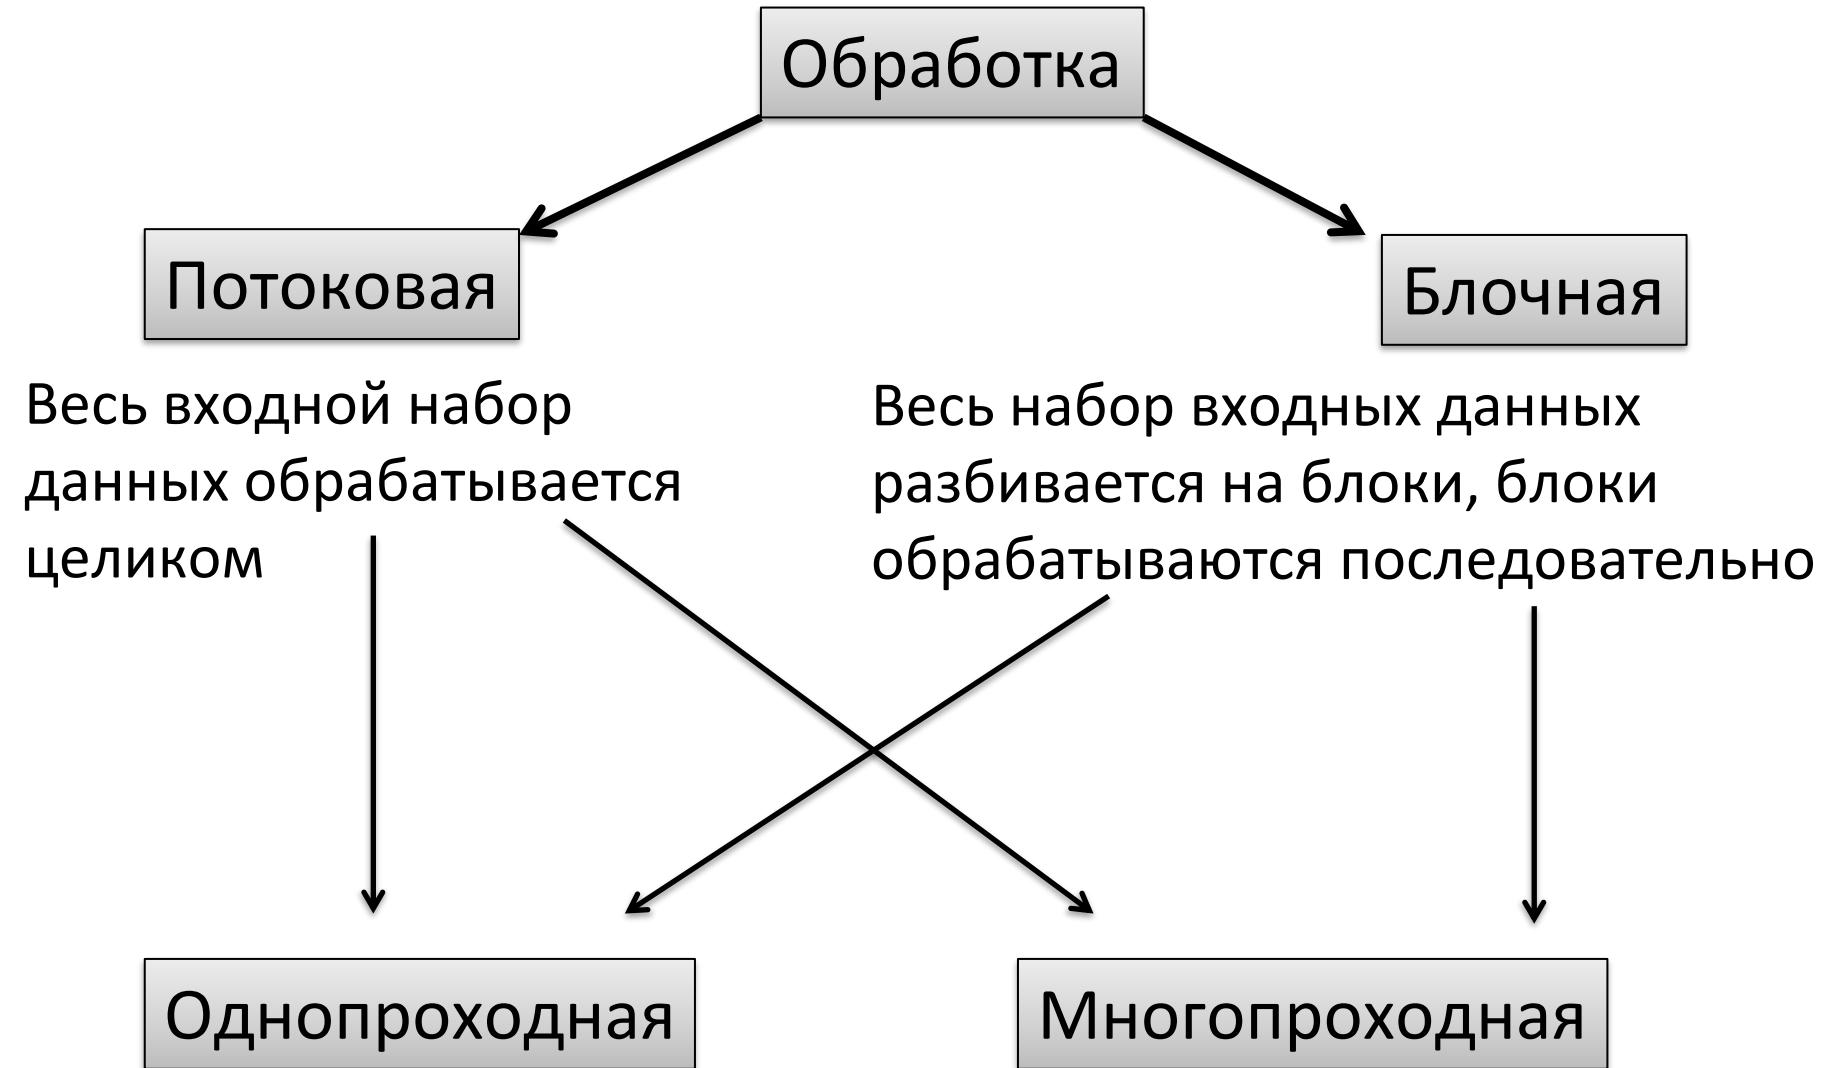
$$K_{\text{сжатия}} = \frac{L_{\text{исходных данных}}}{L_{\text{результата}}}$$

Коэффициент сжатия
определяет
эффективность алгоритма
сжатия

Какие значения может
принимать
коэффициент сжатия
данных?



Типы обработок данных



Простейший алгоритм сжатия : RLE

RLE - Run Length Encoding

Алгоритм:

Кодирование длин серий

1. считываем со входа символы до тех пор, пока идут повторяющиеся символы
2. считаем, сколько одинаковых символов прошло
3. пишем на выход число - сколько одинаковых символов прошло
4. пишем символ, который повторялся
5. повторяем пункты 1-4, пока есть входные данные

Тестовая последовательность:

АААББВГААДДДДДДДДЕЕЖЖЖЖЖЖЖЖЖЖ33333

Результат работы алгоритма сжатия RLE:

ЗА2Б1В1Г2А9Д2Е11Ж53

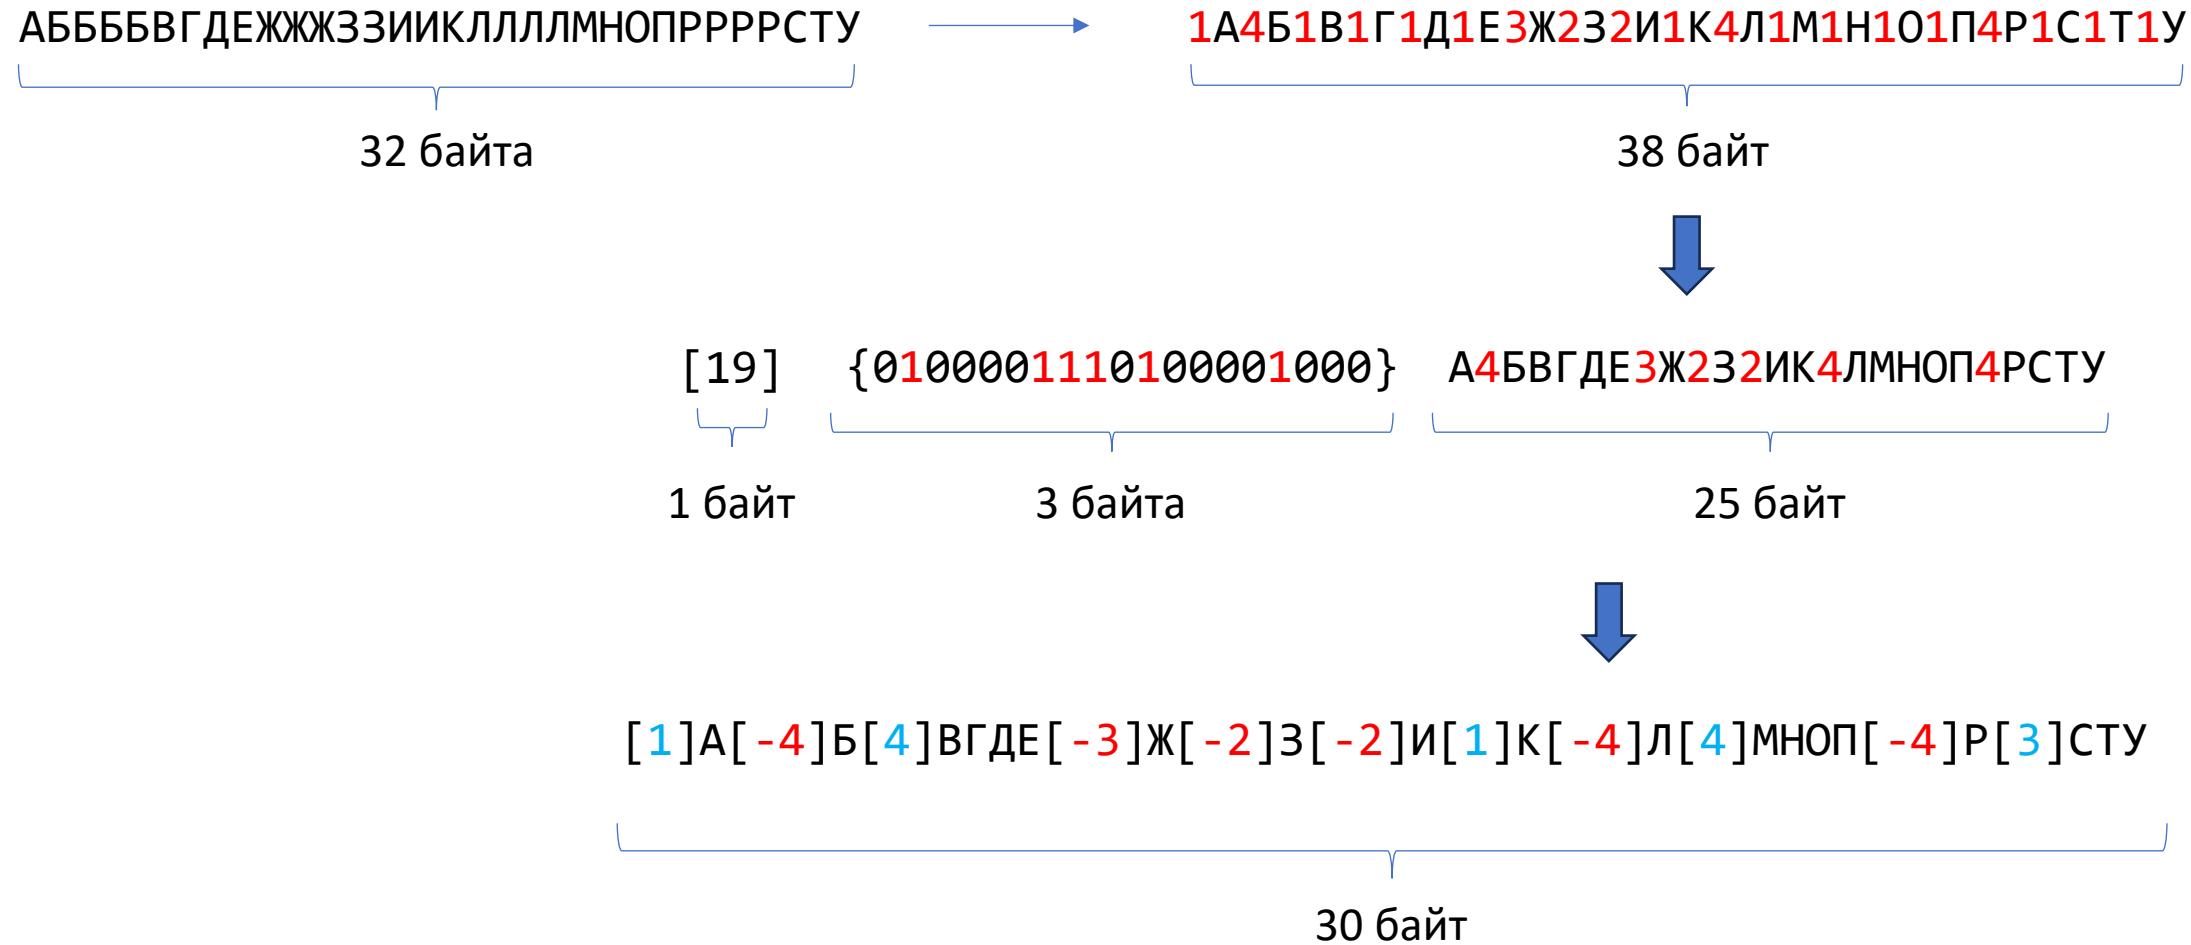
Эффективность алгоритма RLE

Алгоритм эффективен для любых типов файлов, имеющих большое число повторяющихся последовательностей байт

Алгоритм эффективен для типов данных, имеющих большое число повторяющихся типов заранее предопределённых последовательностей

Алгоритм не требует информации о всём наборе данных, может использоваться при передаче данных по каналам связи

Модификации алгоритма RLE: PackBits



Алгоритм Хаффмана

Алгоритм:

- проходим по всему набору данных, посчитаем частоты вхождения символов

- сортируем символы по частоте, с которой они встречаются в наборе данных

- начинаем строить дерево

- 3-а. выбираем 2 символа с минимальными частотами, заносим в дерево

- 3-б. повторяем операцию, наращиваем глубину (высоту) дерева, добавляя к созданному элементу те, которые имеют минимальную частоту.

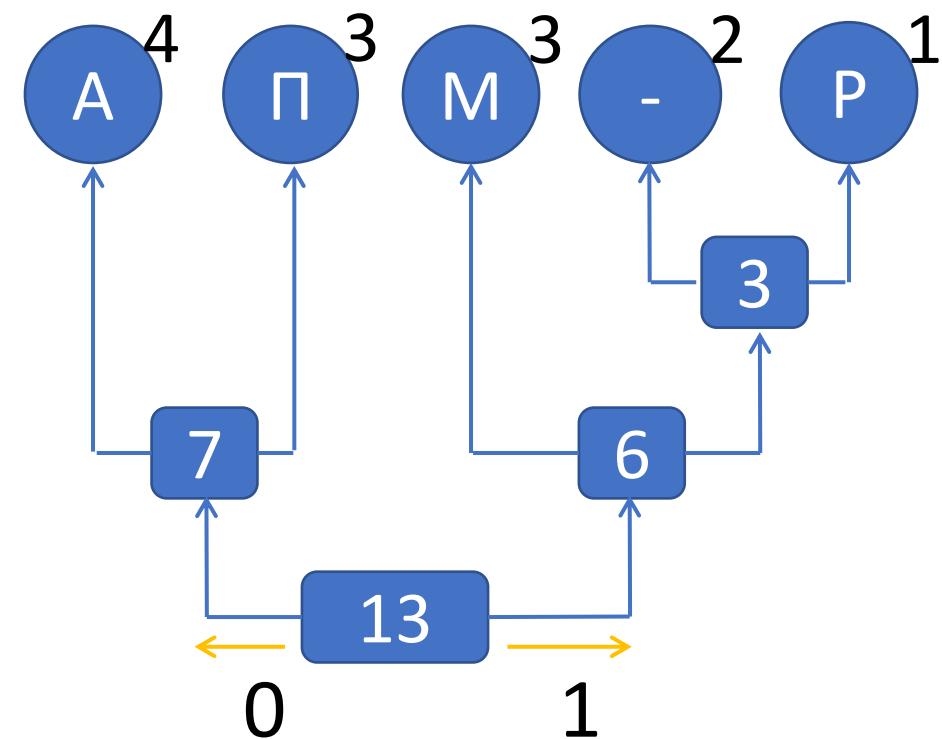
- Выполняем проверку: убеждаемся, что итоговое значение равно сумме частот появления символов

- Строим таблицу путей по дереву для каждого из символов

A	00
П	01
M	10
-	110
P	111

Тестовая последовательность:

ПАРАМ-ПАМ-ПАМ



Алгоритм LZW

Тестовая последовательность:

ПАРАМ-ПАМ-ПАМ

Лемпель, Зив, Уэлч

Алгоритм:

```
STR = data[0];
i = 1;
while(i < data.length) {
    SYM = data[i];

    if(LUT.find(STR + SYM))
        STR = STR + SYM;
    else {
        out << LUT.code_for(STR);
        LUT.add(STR + SYM);
        STR = SYM;
    }
    ++i;
}
```

Алгоритм LZW (2)

Тестовая последовательность:

Выход: П А Р А М - «256»

ПАРАМ-ПАМ-ПАМ

	Таблица	Строка	Символ
STR = data[0]; i = 1; while (i < data.length) { SYM = data[i];	256	ПА	А
if (LUT.find(STR + SYM)) STR = STR + SYM; else { out << LUT.code_for(STR); LUT.add(STR + SYM); STR = SYM; } ++i;	257 258 259 260 261	AP PA AM M- -П	Р А М - П
		П	А
	262	ПАМ	М

Алгоритм LZW (3)

Тестовая последовательность:

Выход: П А Р А М - «256» «260» «262»

ПАРАМ-ПАМ-ПАМ

```
STR = data[0];
i = 1;
while(i < data.length) {
    SYM = data[i];

    if(LUT.find(STR + SYM))
        STR = STR + SYM;
    else {
        out << LUT.code_for(STR);
        LUT.add(STR + SYM);
        STR = SYM;
    }
    ++i;
}
```

	Таблица	Строка	Символ		Таблица	Строка	Символ
STR = data[0];	256	ПА	П	А	261	-П	-
i = 1;							П
while(i < data.length) {	257	AP	A	P	262	ПАМ	ПА
SYM = data[i];							М
if(LUT.find(STR + SYM))	258	PA	P	A			M
STR = STR + SYM;							-
else {	259	AM	A	M	263	M-П	M-
out << LUT.code_for(STR);							П
LUT.add(STR + SYM);	260	M-	M	-			A
STR = SYM;							
}	261	-П	-	П			М
++i;							
			П	А			ПАМ
	262	ПАМ	ПА	М			

Эффективность и характеристики алгоритма LZW

Эффективность

Исходная последовательность:

ПАРАМ-ПАМ-ПАМ

Длина исходной
последовательности:
104 бита

Сжатая последовательность:
ПАРАМ- «256» «260» «262»

Длина сжатой
последовательности: 75 бит

Характеристики

алгоритм является
однопроходным

размер поля таблицы всегда одинаков
(для набора) и зависит от размера
«сканирующего окна»

не требуется хранить информацию о
словаре – очевидно, что его можно
формировать динамически, читая
сжатое сообщение

Блочные и потоковые алгоритмы

Последовательность данных

Подпоследовательность
данных-1

$K_{\text{сжатия_блок1}}$

```
data.block[i].compress();
```

```
if(data.block[i].koeff > 1)
    write(data.block[i].compressed)
else
    write(data.block[i].uncompressed);
```

$K_{\text{сжатия}} < 1$



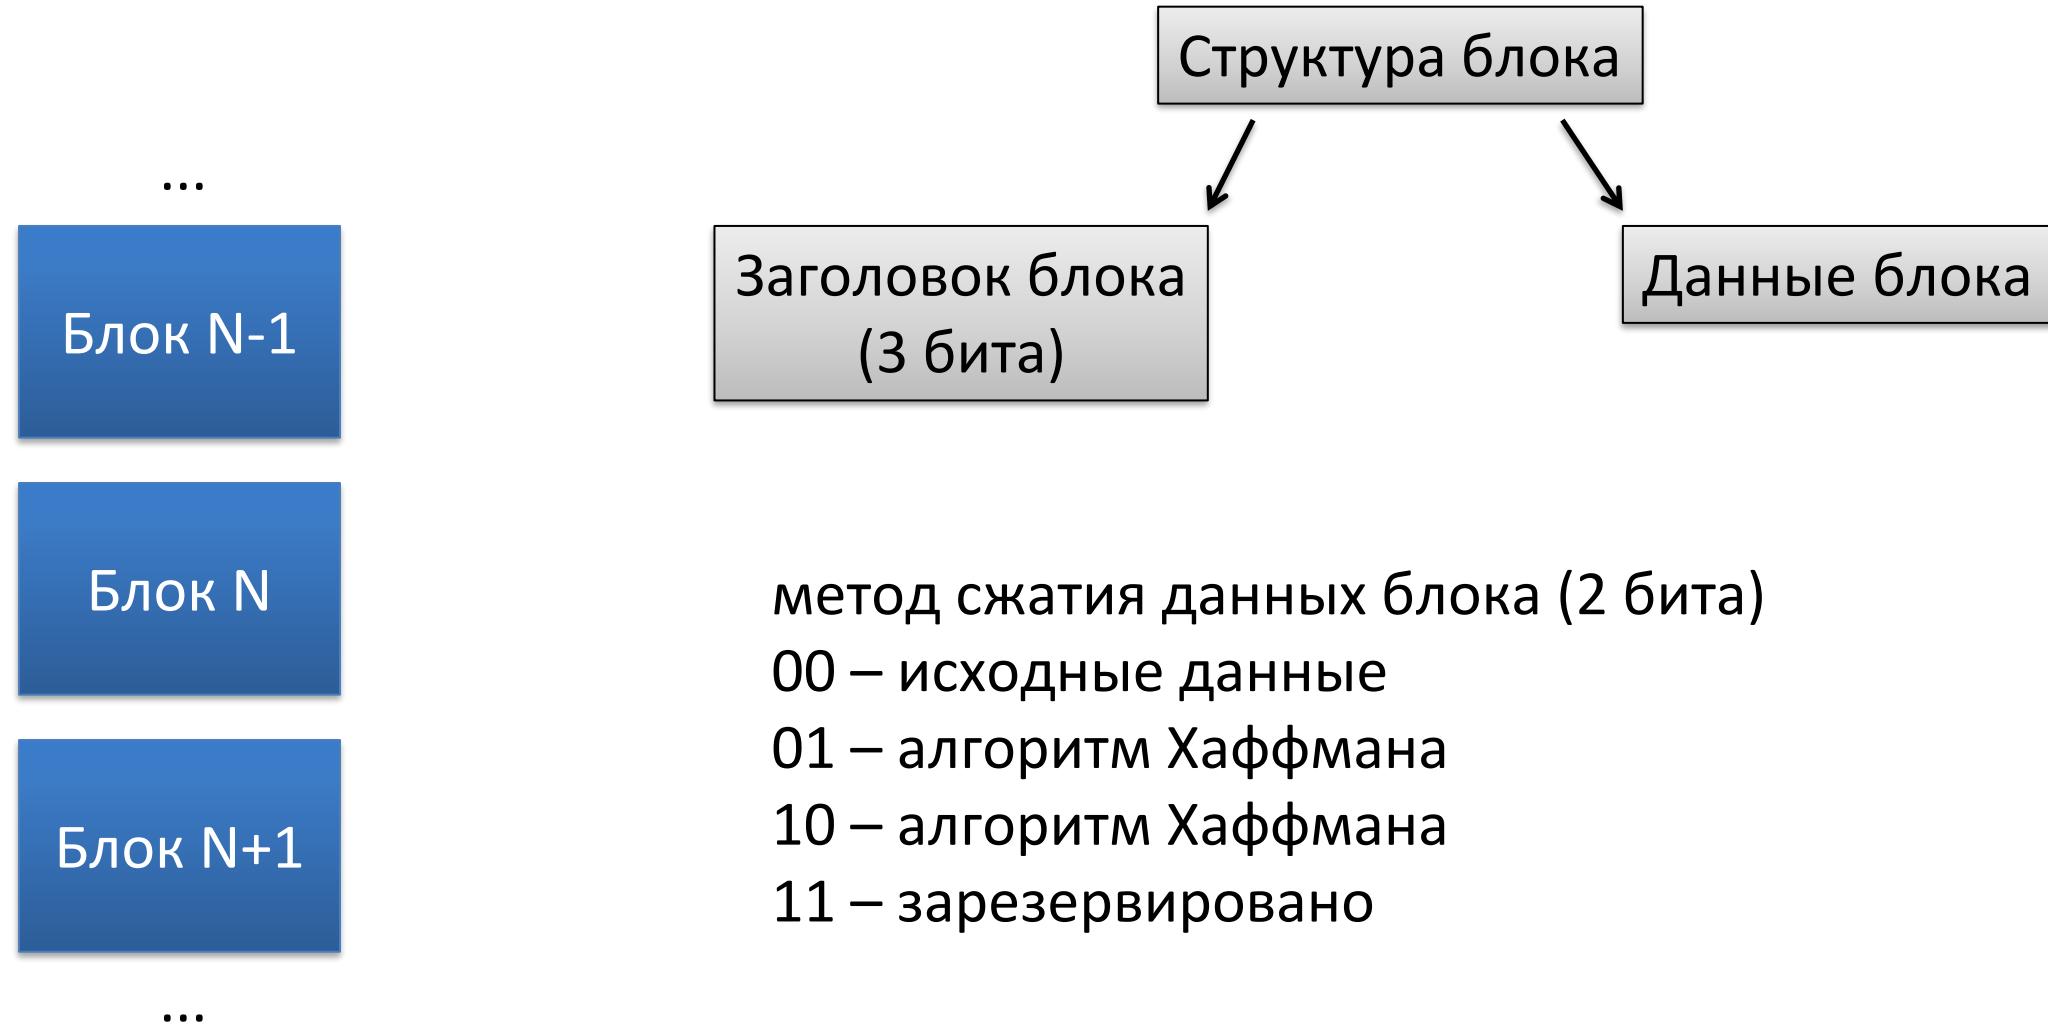
Подпоследовательность
данных-2

$K_{\text{сжатия_блок2}}$

Подпоследовательность
данных-3

$K_{\text{сжатия_блок3}}$

Блочный алгоритм: архиватор ZIP



Блочный алгоритм: архиватор bz2

Алгоритм компрессии:

1. для входной последовательности организуется циклическая перестановка со сдвигом влево;
2. получившаяся последовательность сортируется лексикографически;
3. запоминаем последний столбец;
4. запоминаем номер исходной строки;
5. кодируем последний столбец;

1Р2П2А2М1А, 7

Тестовая последовательность:

ПАРАМПАМ

ПАРАМПАМ	АМПАМПАР
АРАМПАМП	АМПАРАМП
РАМПАМПА	АРАМПАМП
АМПАМПАР	МПАМПАРА
МПАМПАРА	МПАРАМПА
ПАМПАРАМ	ПАМПАРАМ
АМПАРАМП	ПАРАМПАМ
МПАРАМПА	РАМПАМПА

Алгоритмы сжатия

Виды алгоритмов сжатия

Без потерь

- RLE (PCX, BMP, TGA, TIFF)
- Huffman (PNG)
- LZW (GIF)



Сжатие с потерями: формат JPEG

JPEG

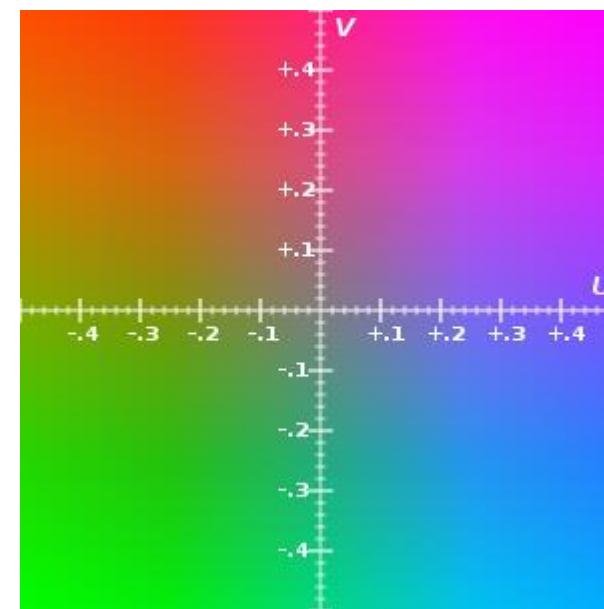
Joint Photographic Experts Group

Основан на переводе RGB в YUV

Y – яркость

U – синяя цветоразностная компонента

V – красная цветоразностная компонента



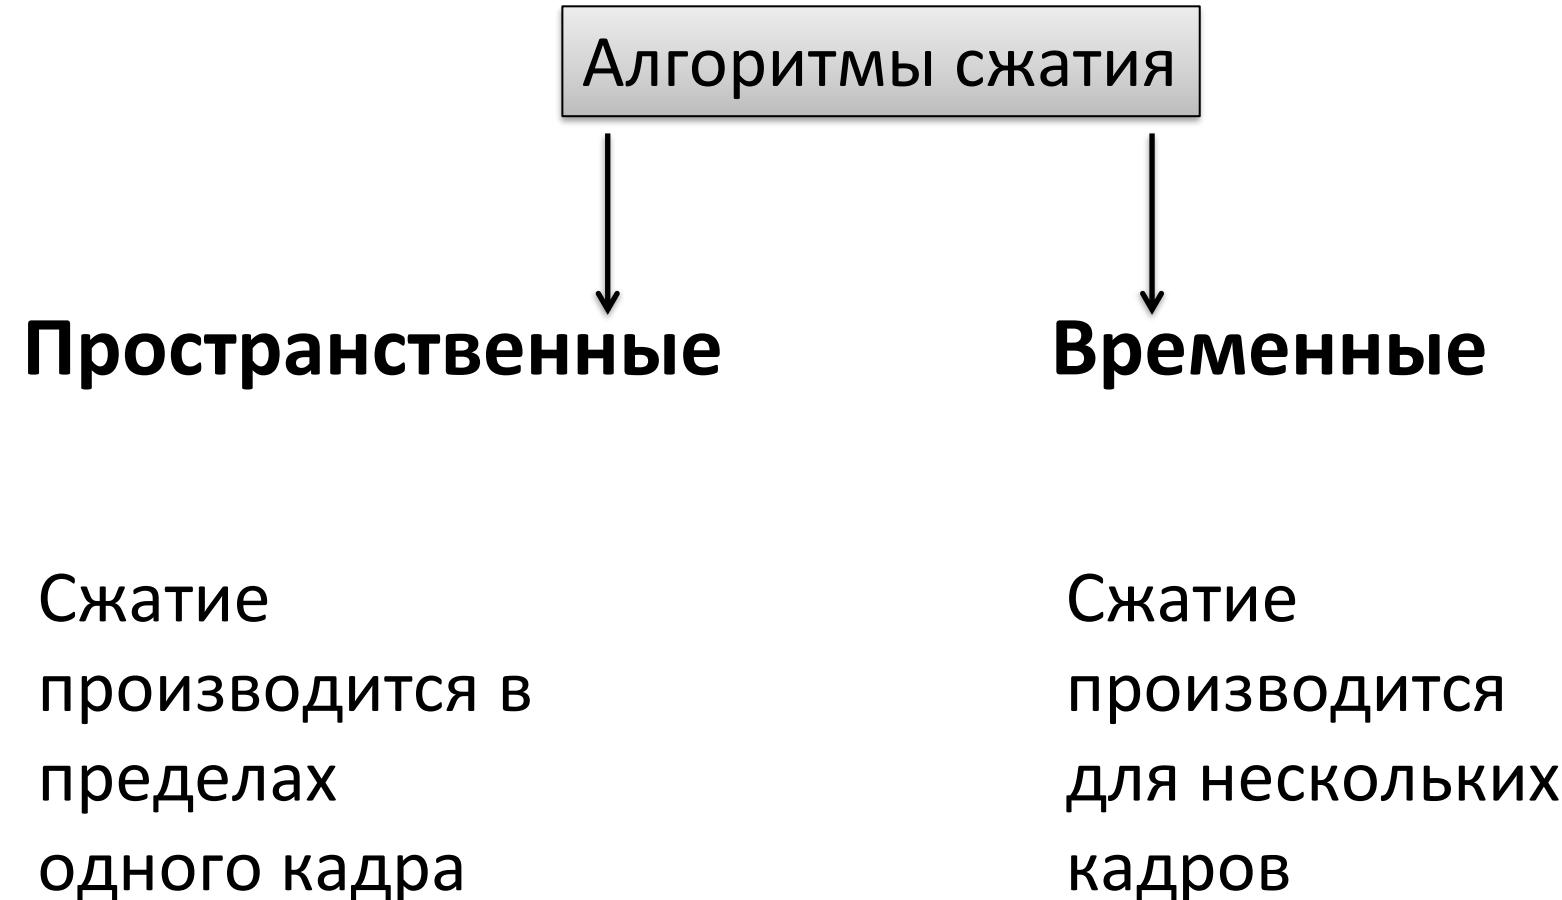
Цветовые пространства YUV и RGB



=



Алгоритмы сжатия видеоданных



Сжатие видеопотока: деинтерлейсинг



Определение макроблоков и векторов движения



Разница кадров с компенсацией



Сжатие видеопотока: временное сжатие

