Сжатие данных

Информационные технологии.

Лекция №2

Коэффициент сжатия

$$K = \frac{V_x}{V_y}$$

V_x – объем входного потока

V_y – объем выходного потока

$$K \neq const$$

для разных данных могут быть:

$$K > 1$$

$$K = 1$$

$$K < 1$$

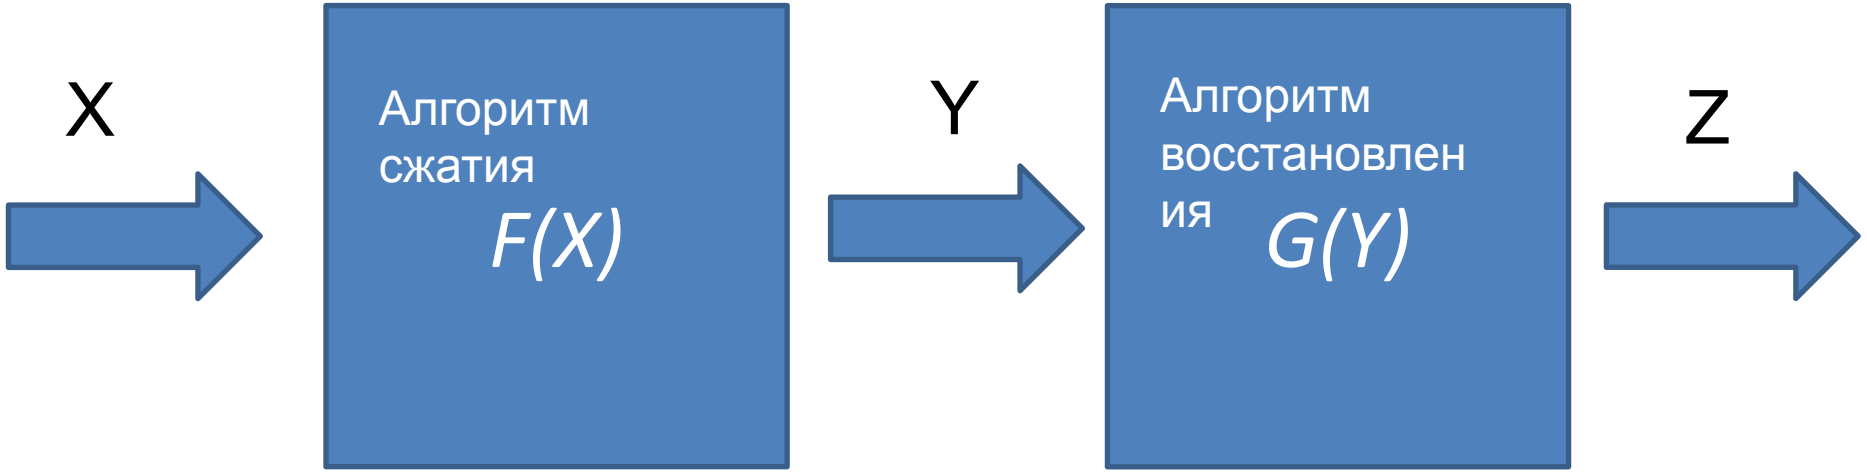

X = Z – сжатие без потерь

X ≠ Z – сжатие с потерями

Пример сжатия с потерями (JPEG)

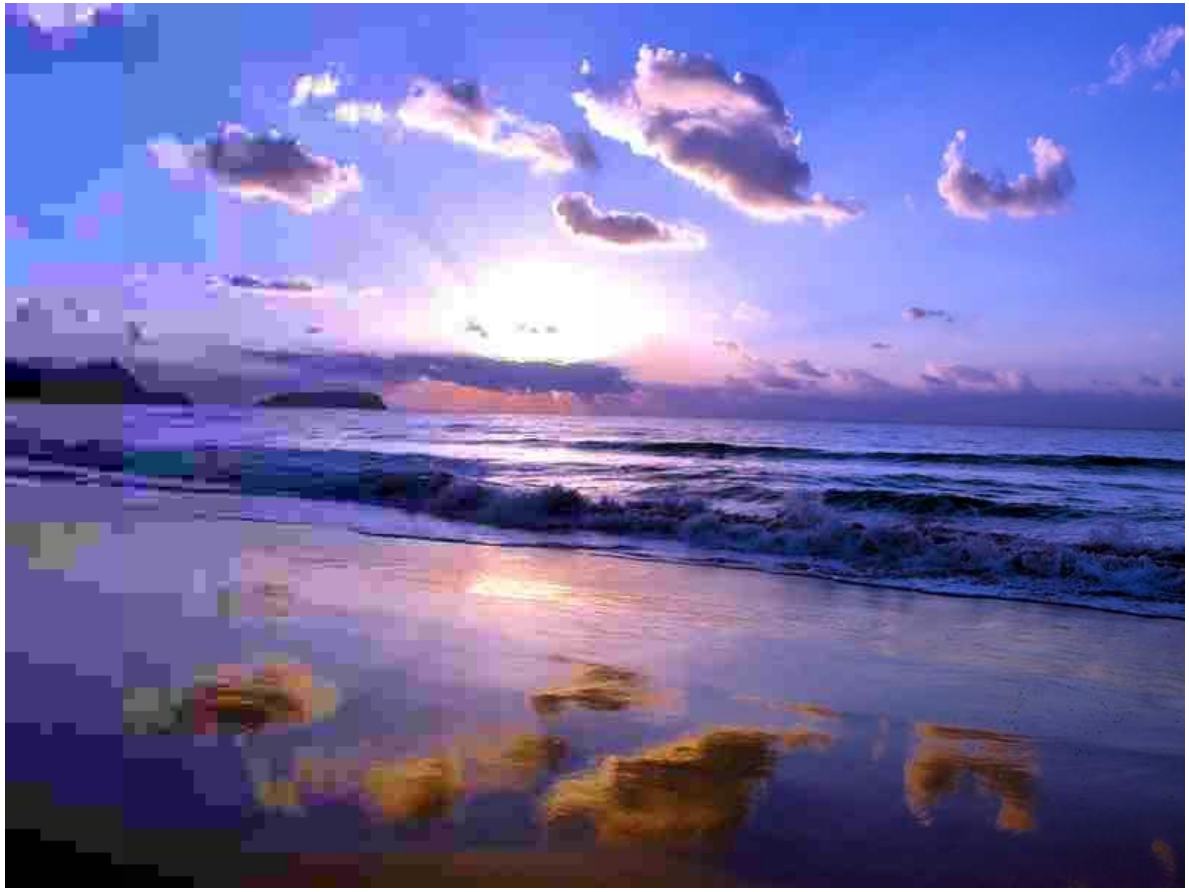

Quality

Статистические алгоритмы сжатия данных

Для сжатия данных используется информация об *энтропии* входного потока.

Используется *частота/вероятность* появления символа в потоке.

Буква	Частота %	Буква	Частота %	Буква	Частота %	Буква	Частота %
О	11,08	**Р**	4,45	**Ы**	1,96	**Х**	0,89
Е, Ё	8,41	**В**	4,33	**Ь**	1,92	**Ш**	0,81
А	7,92	**К**	3,36	**З**	1,75	**Ю**	0,61
И	6,83	**М**	3,26	**Г**	1,74	**Э**	0,38
Н	6,72	**Д**	3,05	**Б**	1,71	**Щ**	0,37
Т	6,18	**П**	2,81	**Ч**	1,47	**Ц**	0,36
С	5,33	**У**	2,80	**Й**	1,12	**Ф**	0,19
Л	5,00	**Я**	2,13	**Ж**	1,05	**Ъ**	0,02

Примеры алгоритмов:

1. Алгоритм Шеннона-Фано.
2. Алгоритм Хаффмана.
3. Арифметическое кодирование.

Алгоритм Хаффмана

1. *Определить частотную таблицу* символов входного потока данных.
2. *Упорядочить таблицу по убыванию* частоты символов.
3. *Построить дерево Хаффмана* по частотной таблице.
4. *Определить коды символов* по дереву Хаффмана.
5. *Закодировать сообщение* – сформировать выходной поток.

Задача

Дистанционно управляемый робот должен пройти лабиринт (клеточный). Оптимальный алгоритм прохождения лабиринта известен, но необходимо его (алгоритм) закодировать.

Робот способен выполнять следующие команды:

1) Идти вперед (1 кл.)
2) Повернуть вправо на 90 градусов
3) Повернуть влево на 90 градусов
4) Повернуться на 180 градусов
5) Перепрыгнуть обрыв

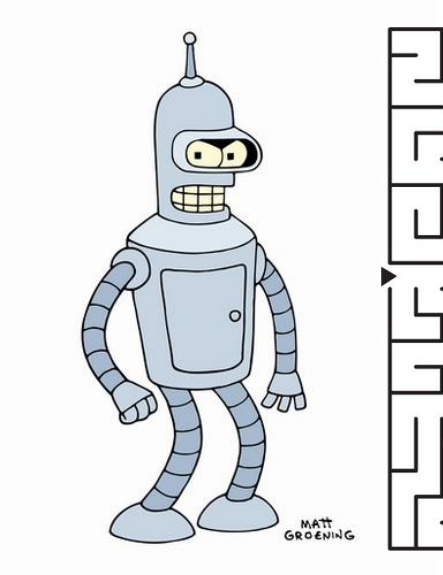

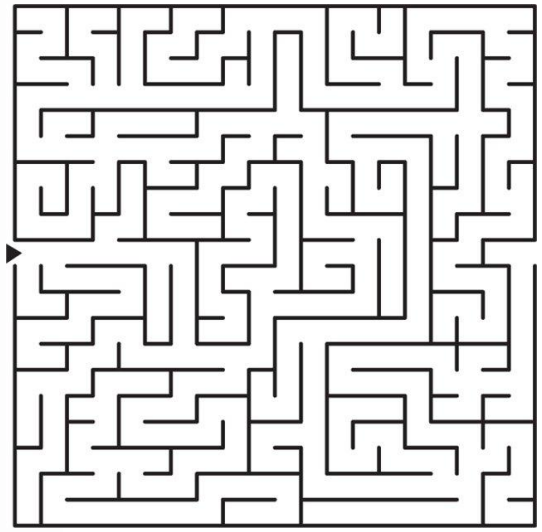

В результате исследования была найдена оптимальная последовательность:

111121113111121113111311132111111
131121213111111111111211131151121 1
111311112113111112111131111111112
111311111311511131111112111131131 11
111311112111121111211112111211211 31
111111111511131112111311311312131 3

Решение

Количество шагов алгоритма (символов) - 223

Частотная таблица

Символ	Частота
1	175
2	20
3	25
4	0
5	3

Пример 2

Количество шагов алгоритма (символов) - 223

Частотная таблица

Символ	Частота
1	80
2	50
3	60
4	0
5	33

Арифметическое кодирование

1. *Определить вероятностную таблицу* символов входного потока данных.
2. Разделить отрезок [0;1) на отрезки в соответствии с вероятностями символов.
3. Поочередно кодировать символы входного потока на получившихся отрезках.

Пример арифметического кодирования

Данные возьмем из предыдущей задачи (алгоритм Хаффмана).

Вероятностная таблица

Символ	Частота	Вероятность
1	175	0,78
2	20	0,09
3	25	0,11
4	0	0,02
5	3	0

Пример арифметического кодирования

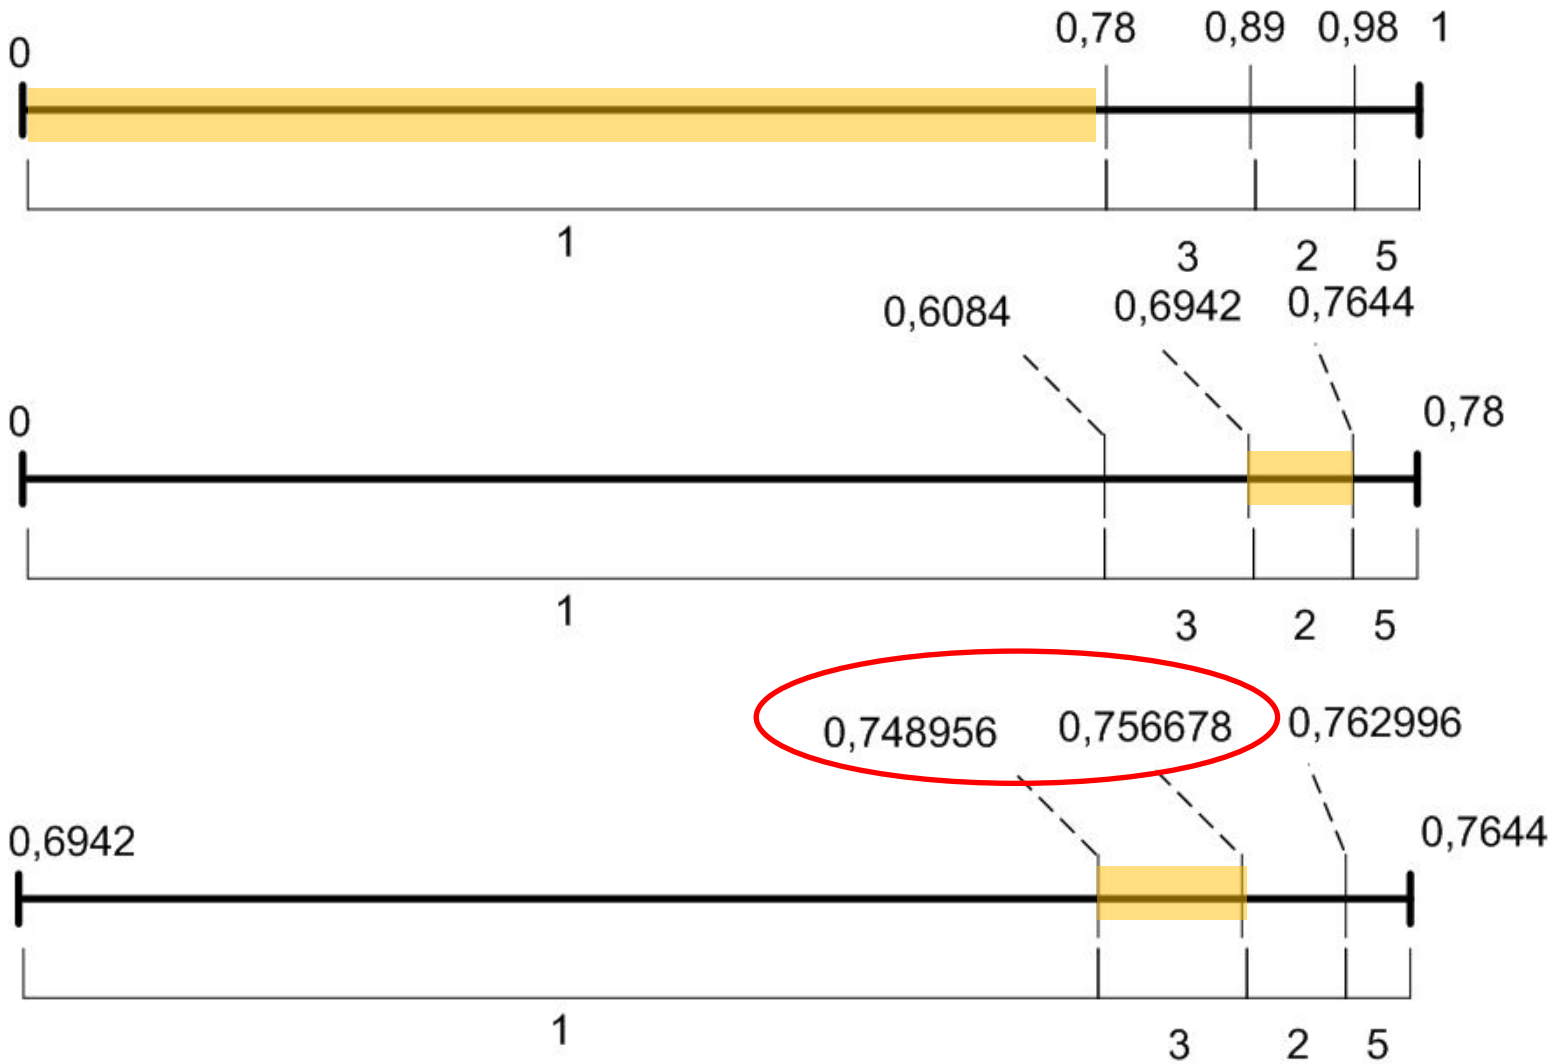

RLE

Run-length encoding – кодирование длин серий

Пример:

1111211131111211131113111311121111113111212131111111111111211131151121111131111211131111111111211131111311151113111111211113113111111311112111121111211121121131111111111511131112111311311312131311131112113 11

1111211131111211131113111311121111113112121311111111111211131151121111131111211131111111111211131111311151113111111211113113111111311112111121111211121121131111111111511131112111311311312131311131112113 11

Другие популярные алгоритмы

LZ77

LZW

BWT

DEFLATE