СЕТЕВЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Сжатие без потерь

Сжатие без потерь (lossless compression). Информация не теряется. Распакованные данные идентичны исходным несжатым данным.

Сжатие с потерями (lossy compression). Распакованные данные могут быть приемлемым приближением к исходным несжатым данным.

Сжатие без потерь

Метод подавления нулей (null suppression):

BISYNC IBM 3780

Передатчик сканирует данные в поиске строк пробелов и заменяет каждую такую строку двухсимвольным кодом. Код состоит из специального управляющего символа, за которым следует число пробелов в строке. Например, пусть имеется код с символами пробела, обозначенными знаком “b”:

XYZbbbbbQRX

Эта строка заменяется следующей строкой, в которой S_c представляет собой специальный управляющий символ:

$XYZS_c5QRX$

Такая схема позволяет сделать короче все строки из трех и более пробелов.

Сжатие без потерь

Групповое кодирование :

Обобщение метода подавления нулей и применяется для сжатия повторяющихся данных любого типа. На рисунке иллюстрируется применение данного метода к символьным данным. Здесь используются следующие обозначения:

- **Sc — специальный символ, указывающий на то, что за ним следуют сжатые данные;**
- **X — любой повторяющийся символ;**
- **Cc — счетчик символов, то есть количество повторений сжатого символа.**

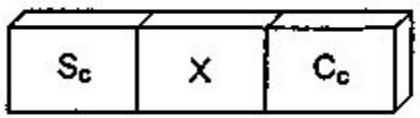

Пример сжатия при групповом кодировании

Исходная строка данных	Кодированная строка данных
$******55.72	$$S_c$*655.72
--------	S_c-9
GunsbbbbbbbbbButter	GunsS_cb9Butter

Сжатие без потерь

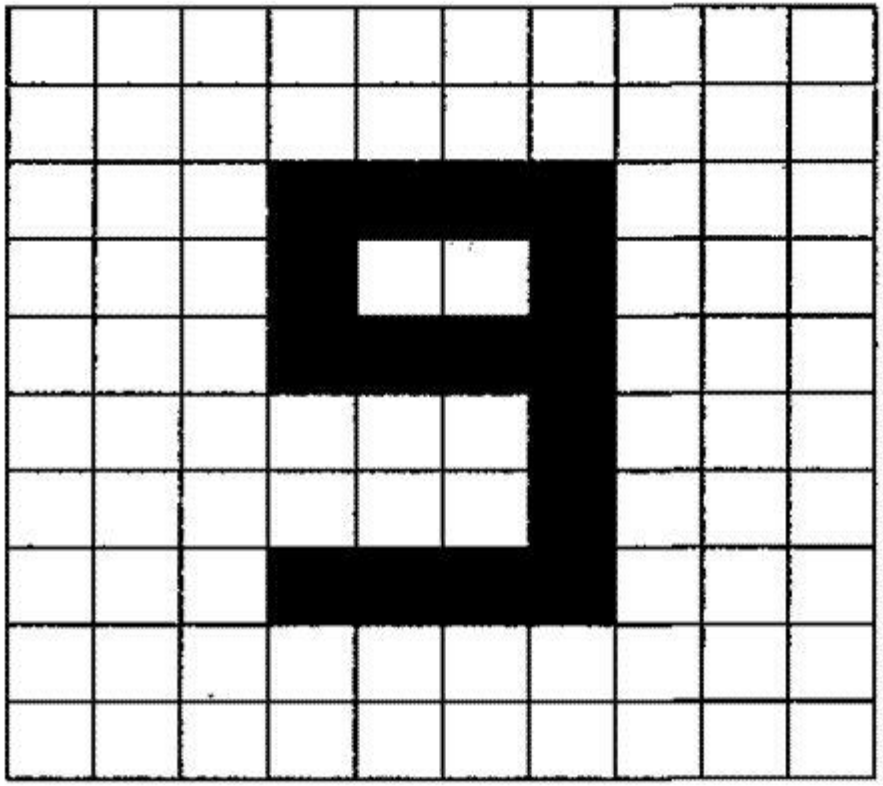

ИЗОБРАЖЕНИЕ

0000000000
0000000000
000**1111**000
000**1**00**1**000
000**1111**000
000000**1**000
000000**1**000
000**1111**000
0000000000
0000000000
Длина равна 100 бит

ДВОИЧНЫЙ КОД:

23W 4B 6W 1B 2W 1B 6W 4B 9W 1B 9W 1B 6W 4B 23W

или

23 4 6 1 2 1 6 4 9 1 9 1 6 4 23

Длина равна 15 символов или 120 бит

Сжатие без потерь

Факсимильное сжатие:

Страница, отсканированная с разрешением 200 пел (белых или черных точек на дюйм): 3 740 000 бит (8.5” x 11” x 40 000 пелов на кв. дюйм)
ISDN (64 Кбит/с) – время передачи ~1 мин.

Два метода сжатия данных без потерь для факсимильной связи:

- модифицированный код Хаффмана - группа 3.
- модифицированный код READ (Relative Element Address Designate — относительное назначение адресов элементов) - группа 4.

Группа 3. **Кодирование черных и белых значений с плотностью в 200 точек на дюйм (гориз.) и 100…200 (верт.). Предполагается, что передача сигнала осуществляется через модем по аналоговой телефонной линии. Передача данных ускоряется в три и более раз по сравнению с группой 2.**

Группа 4. **Черно-белый цифровой факсимильный стандарт. Эта группа предназначена для использования в цифровых сетях со скоростями до 64 Кбит/с. Стандартизированы разрешения от 200 до 400 точек на дюйм.Время передачи одной страницы сокращено до нескольких секунд по сравнению с несколькими минутами в предыдущих стандартах.**

Сжатие без потерь

Модифицированный код Хаффмана:

W7, B7, W4, B8, W4, B7, W10

ITU-T: 1728 точек на линию
Длина серии *N* рассматривается как сумма двух слагаемых:

$$N = 64m + n;\ m = 0, 1, 2, \ldots 27;\ n = 0, 1, 2, \ldots 63$$

P: строка из 200 черных точек: 64*3 + 8
EOL (End Of Line — конец строки)

Сжатие без потерь

Арифметическое кодирование. Основная концепция.

$$\log\left(\frac{1}{P_i}\right) \le L_i \le \log\left(\frac{1}{P_i}\right) + 1 \qquad H(X) \le E[L] < H(X) + 1$$

H(X) **- энтропия множества символов *X*,**
E[L] **– средняя длина кода для множества *X*.**

В схеме сжатия без потерь *H(X)* всегда будет нижней границей объема сжатых данных, так как *H(X)* определяет среднее количество информации, содержащейся в символьном наборе. Эффективность алгоритма сжатия может быть повышена путем объединения символов и одновременного кодирования блоков по *K* символов каждый. В результате мы получаем следующее неравенство:

$$H(X) \le \frac{E[L]}{K} < H(X) + \frac{1}{K}$$

Сжатие без потерь

Арифметическое кодирование. Основная концепция.

Таким образом, существует способ повышения эффективности алгоритма сжатия. Если нам нужно отправить сообщение длиной в *N* символов, мы можем использовать блок длиной *N*. Таким образом, мы обращаемся с каждым сообщением как с одним из M^N возможных результатов, где *M* представляет собой количество атомарных символов, а *N* — длину сообщения.

$P_{AAA}=0.512$, $P_{BAA}=0.128$,
$P_{AAB}=0.128$, $P_{BAB}=0.032$,
$P_{ABA}=0.128$, $P_{BBA}=0.032$,
$P_{ABB}=0.032$, $P_{BBB}=0.032$.

Для сообщения с восемью возможными результатами это разумно, но при очень длинных сообщениях использование этого метода приведет к большим вычислительным затратам.

Сжатие без потерь

Арифметическое кодирование. Основная концепция.

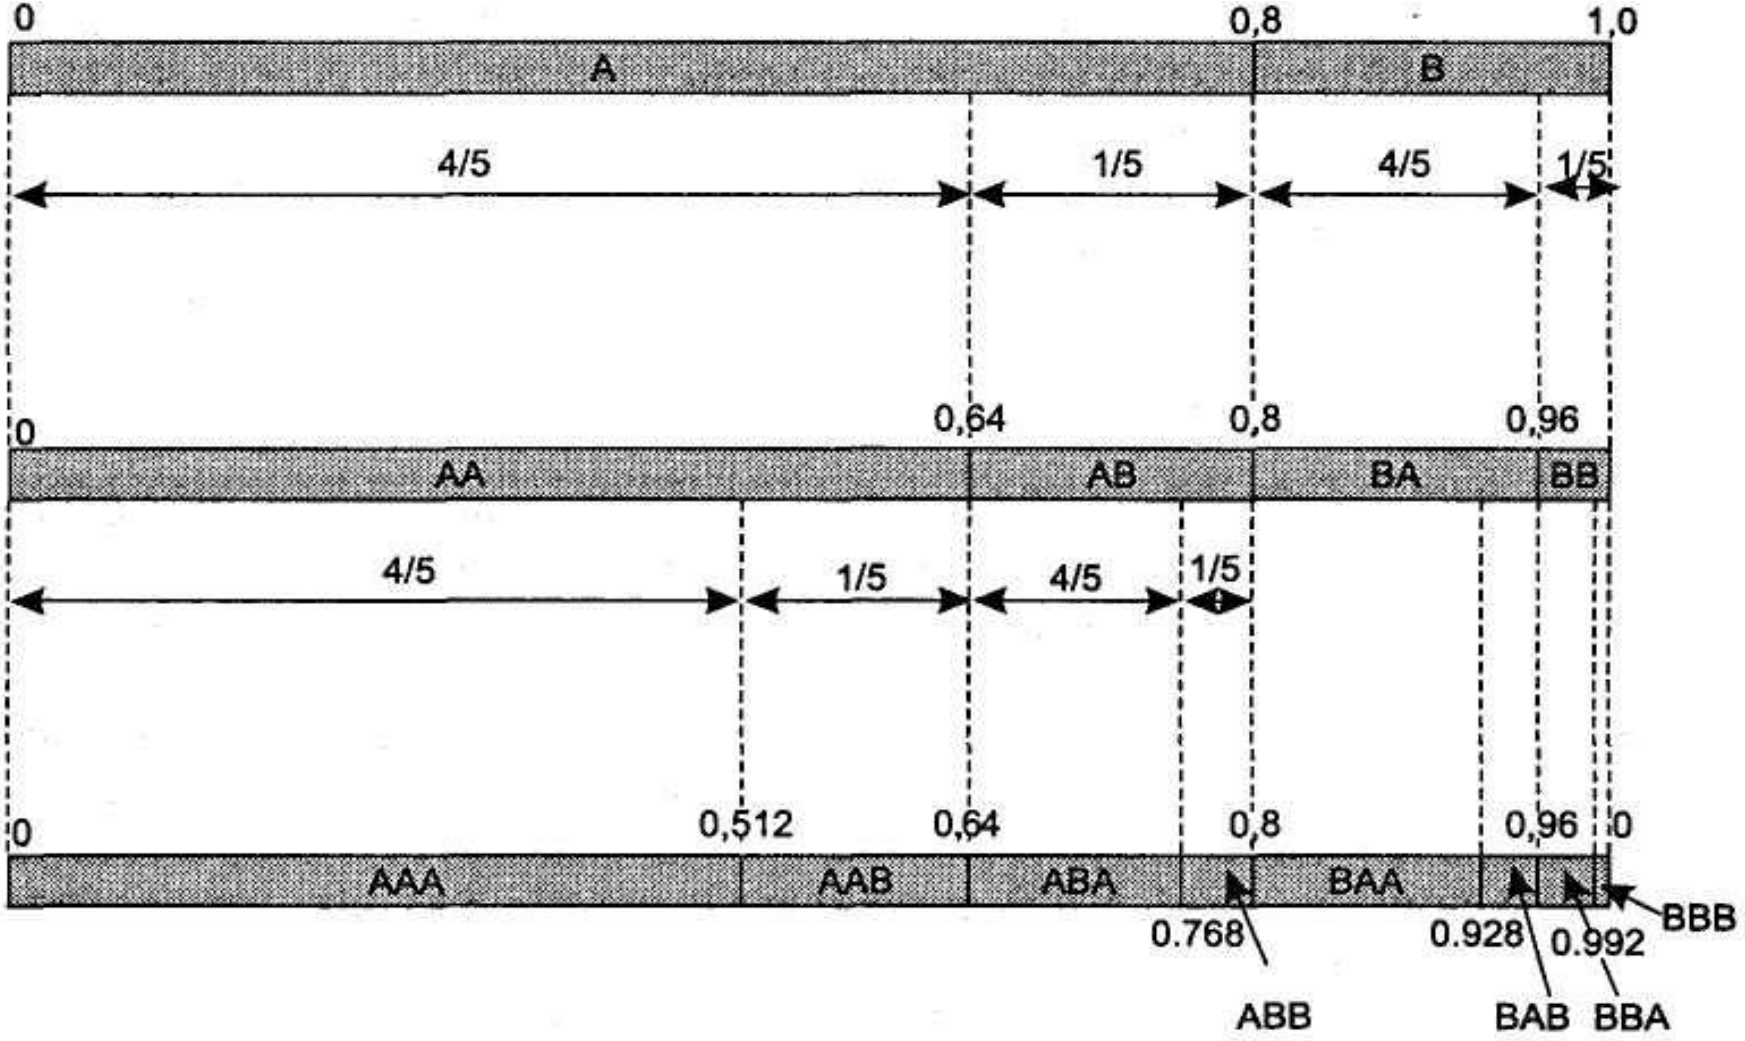

Сжатие без потерь

Арифметическое кодирование. Основная концепция.

Теперь результату каждого сообщения поставлен в соответствие интервал, пропорциональный вероятности сообщения. Таким образом, каждый результат может быть представлен двоичным дробным числом, равным некоторой точке на интервале.

Последова-тельность	P_i	Кумуля-тивная вероят-ность	Интервал	Двоичное представление нижней границы	Код	P_iL_i	$P_i\log(1/P_i)$
AAA	0.512	0.512	[0,0.512]	0.00000	0	0.512	0.494
AAB	0.128	0.64	[0.512,0.64]	0.10000	100	0.384	0.38
ABA	0.128	0.768	[0.64,0.768]	0.10100	101	0.384	0.38
ABB	0.032	0.8	[0.768,0.8]	0.11000	11000	0.16	0.159
BAA	0.128	0.928	[0.8,0.928]	0.11001	11001	0.64	0.38
BAB	0.032	0.96	[0.928,0.96]	0.11101	111	0.096	0.159
BBA	0.032	0.992	[0.96,0.992]	0.11110	11110	0.096	0.159
BBB	0.008	1.0	[0.992,1.0]	0.11111	11111	0.04	0.056
						2.408	2.167

Сжатие без потерь

Чистое арифметическое кодирование:

БАЗОВЫЙ АЛГОРИТМ:

Каждый шаг алгоритма начинается с полуоткрытого интервала

***[L, H)*, вначале инициализируемого как [0,1)**

- **Текущий интервал разбивается на подынтервалы по одному для каждого возможного символа. Каждый подынтервал пропорционален вероятности, с которой соответствующий символ встречается в тексте.**
- **Выбирается подынтервал, соответствующий текущему символу. Этот подынтервал становится текущим интервалом.**
- **Если обработано все сообщение, выполняется следующий шаг, если нет, возвращаемся к шагу 1.**
- **Выводится количество битов, достаточное для того, чтобы можно было отличить данный интервал от двух соседних интервалов.**
- **Выводится некий специальный код конца сообщения, чтобы уведомить получателя.**

Сжатие без потерь

Арифметическое кодирование :

ПРИМЕР1:

Пусть имеются два символа, a и b, вероятности которых зависят от положения в трехсимвольном общении:

$Pr(a_1) = 2/3$, $Pr(b_1) = 1/3$,
$Pr(a_2) = 1/2$, $Pr(b_2) = 1/2$,
$Pr(a_3) = 3/5$, $Pr(b_3) = 2/5$.

Здесь $Pr(a_i)$ представляет собой вероятность того, что символ a встретится в i-й позиции сообщения. В данном случае кодируется сообщение «bab».

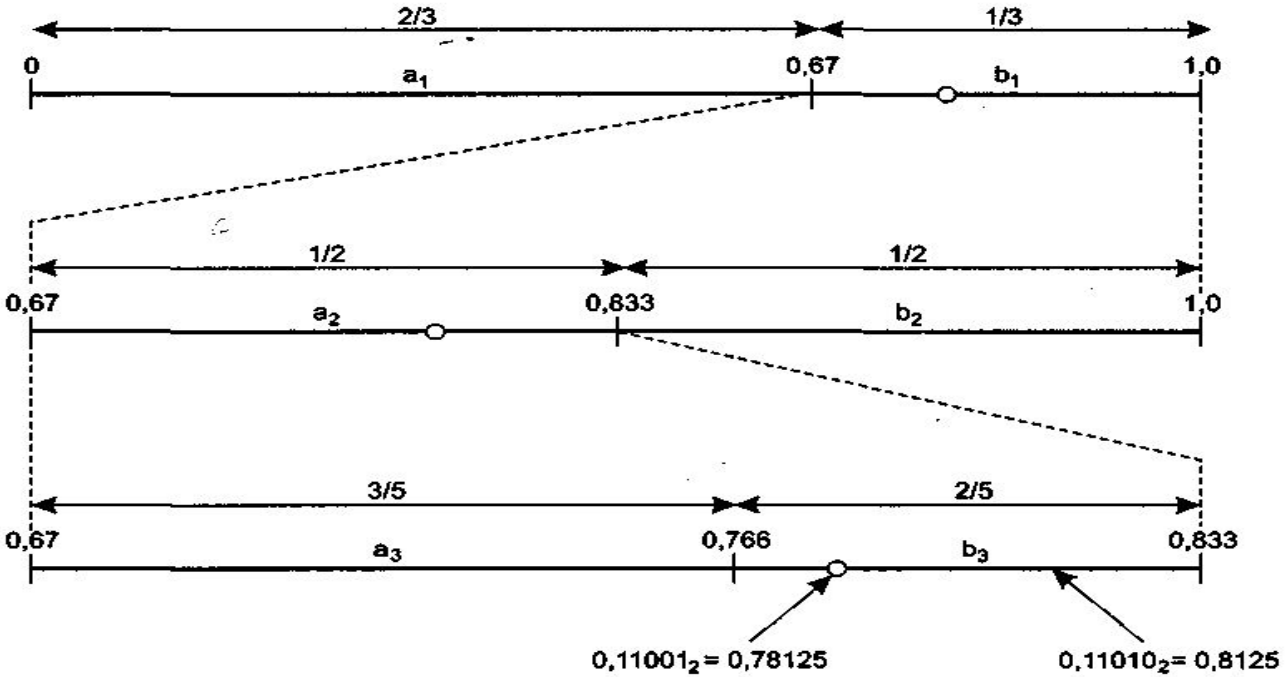

Сжатие без потерь

Инкрементное арифметическое кодирование

Недостатки арифметического кодирования:

- уменьшающиеся размеры текущего интервала требуют все более точных вычислений;
- код не может быть передан, пока не закодировано все сообщение.

[L, H) = [0, 1)

Используется счетчик следования (FC)