

Алгоритм построения орграфа Хаффмана (алгоритм сжатия)


Учитель информатики:

Константинова Елена Ивановна

Муниципальное образовательное
учреждение Раменская средняя
общеобразовательная школа №8

Давид Хаффман (1925-1999)

Давид начал свою научную карьеру студентом в Массачусетском технологическом институте (MIT), где построил свои коды в начале пятидесятых годов прошлого века.

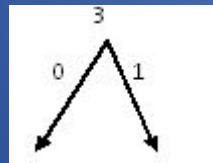


Закодируем предложение «НА_ДВОРЕ_ТРАВА,_НА_ТРАВЕ_ДРОВА»

Вначале нужно подсчитать количество вхождений каждого символа в тексте.

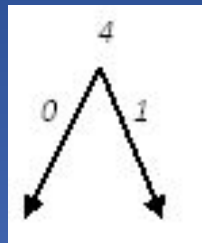
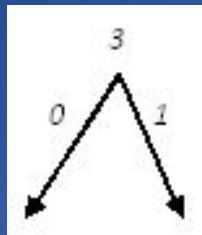
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	_

Создаем первый узел



6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	_

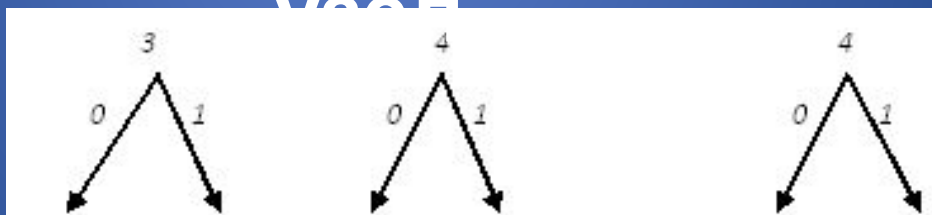
Создаем еще один узел



6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

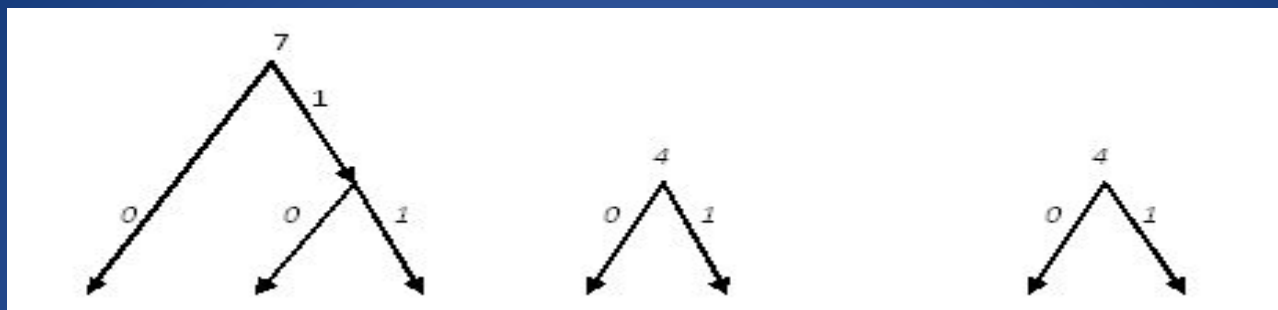
Создаем еще один

узел



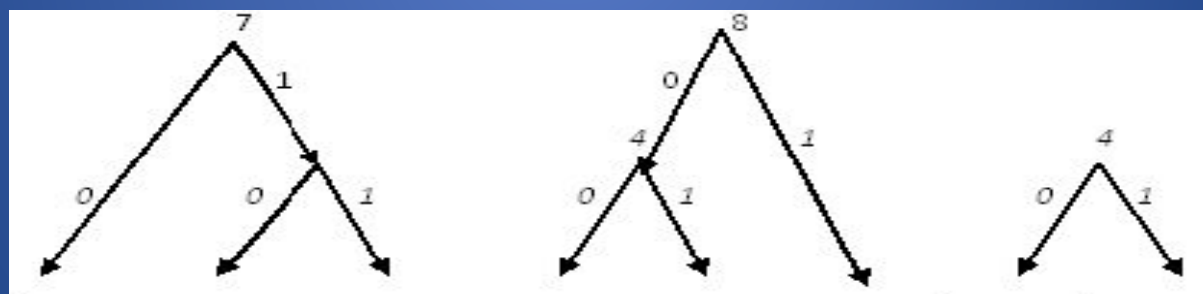
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Создаем еще один узел



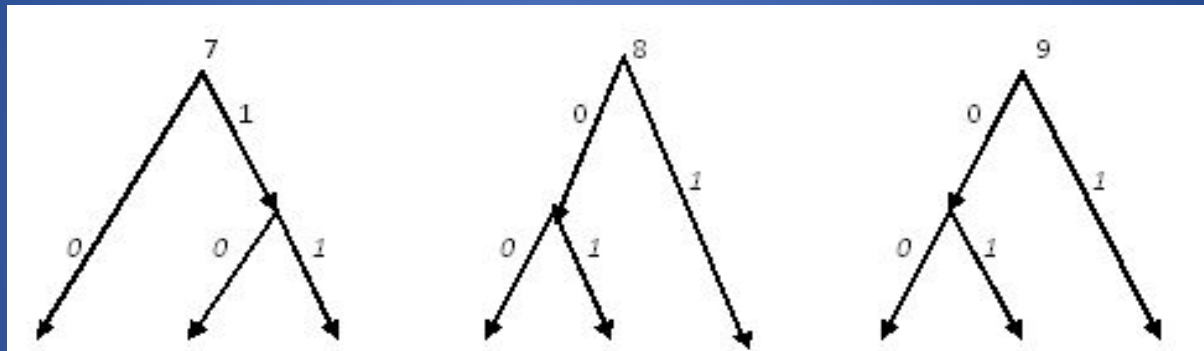
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Создаем еще один узел



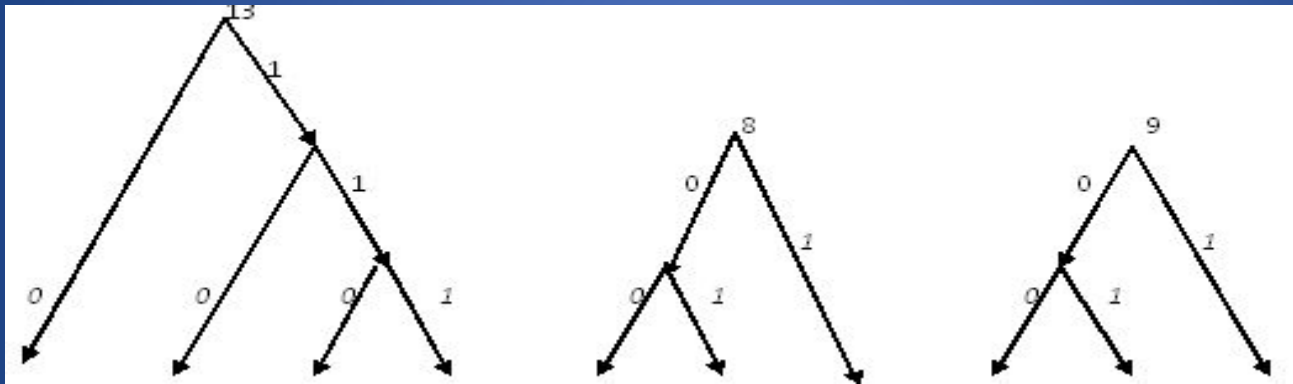
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Создаем еще один узел



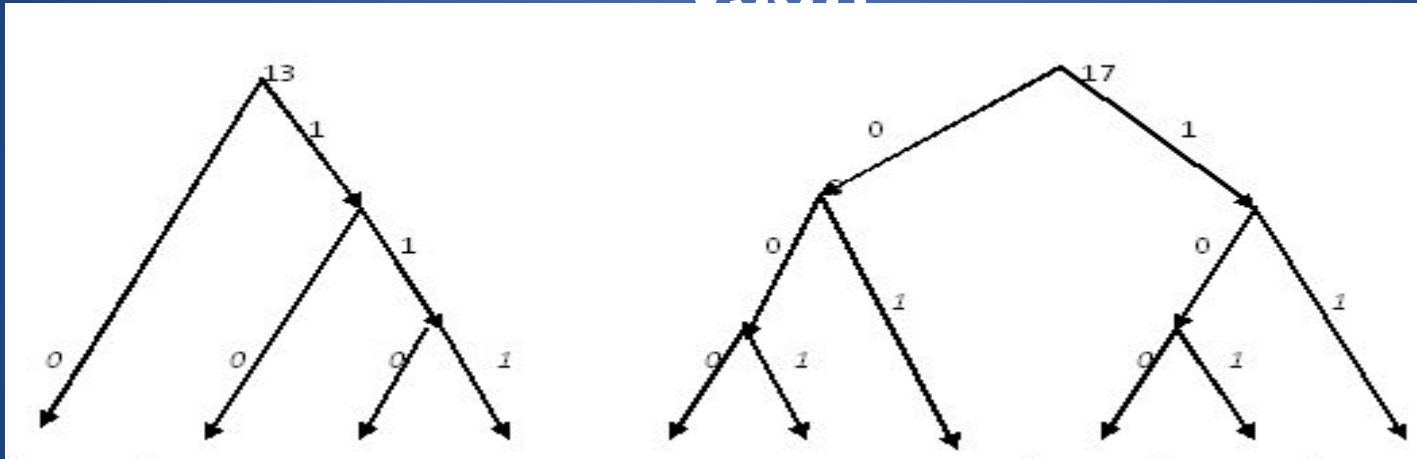
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	_

Создаем еще один узел



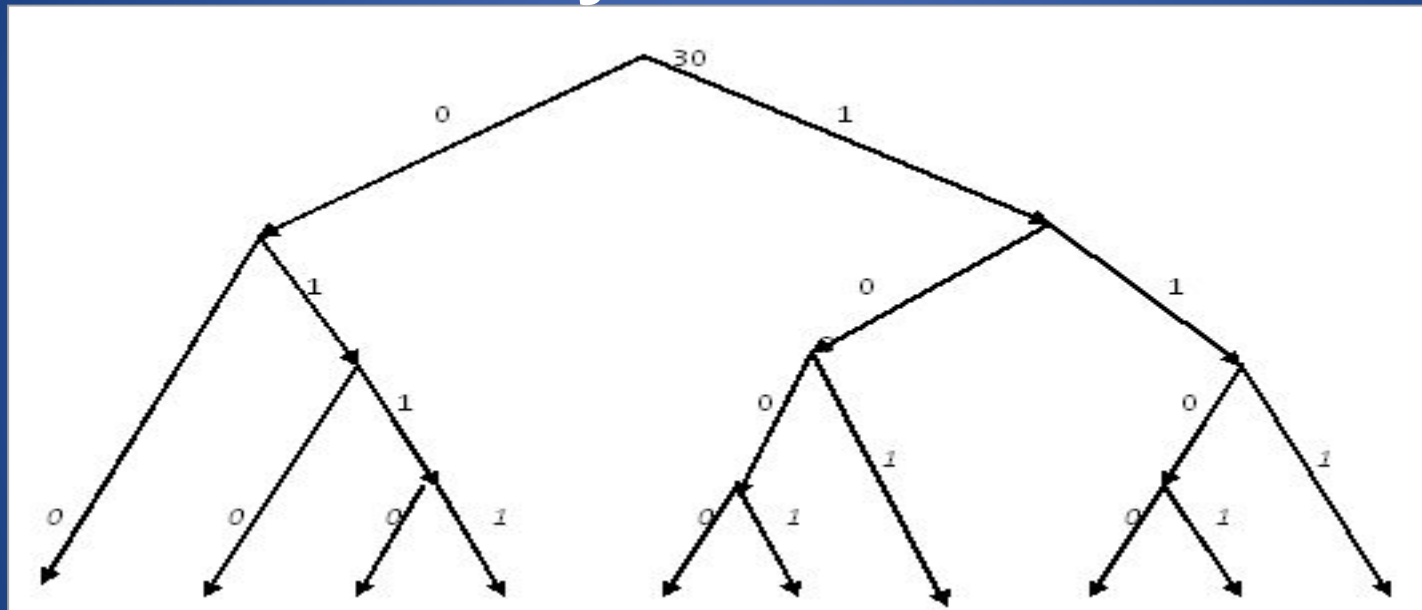
6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Создаем еще один узел



6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Создаем еще один узел



6	4	2	1	2	2	4	2	2	5
а	в	д	,	е	н	р	о	т	—

Чтобы определить код для каждого из символов, входящих в сообщение, мы должны пройти путь от листа дерева, соответствующего этому символу, до корня дерева, накапливая биты при перемещении по ветвям дерева. Полученная таким образом последовательность битов является кодом данного символа, записанным в обратном порядке.

а	в	д	,	е	н	р	о	т	_
00	010	0110	0111	1000	1001	101	1100	1101	111
6	4	2	1	2	2	4	2	2	5

ПОДСЧИТАЕМ, СКОЛЬКО ДВОИЧНЫХ СИМВОЛОВ ОКАЖЕТСЯ В СООБЩЕНИИ

«НА_ДВОРЕ_ТРАВА,_НА_ТРАВЕ_ДРОВА»

ДЛЯ ЭТОГО НАДО НАЙТИ ПРОИЗВЕДЕНИЕ ЧИСЛА СИМВОЛОВ В КОДЕ КАЖДОЙ БУКВЫ НА КОЛИЧЕСТВО РАЗ, КОТОРОЕ ЭТА БУКВА ВСТРЕЧАЕТСЯ В СООБЩЕНИИ, А ЗАТЕМ ПОЛУЧЕННЫЕ ПРОИЗВЕДЕНИЯ СЛОЖИТЬ. ПОЛУЧАЕМ:

$$2*6+3*4+4*2+4*1+4*2+4*2+3*4+4*2+4*2+3*5=95$$

ПОСКОЛЬКУ В СООБЩЕНИИ ИСПОЛЬЗУЕТСЯ **10** РАЗЛИЧНЫХ СИМВОЛОВ, ДЛЯ ИХ КОДИРОВАНИЯ ТРЕБУЕТСЯ КАК МИНИМУМ ЧЕТЫРЕХБИТОВЫЕ ЦЕПОЧКИ, ПОЭТОМУ ПОСЛЕ КОДИРОВАНИЯ ДАННОГО СООБЩЕНИЯ ПОЛУЧИТСЯ ЦЕПОЧКА ОБЪЕМОМ **120** БИТ.

КОЭФФИЦИЕНТ СЖАТИЯ ЭТО ОТНОШЕНИЕ ОБЪЕМА ИСХОДНОГО СООБЩЕНИЯ К ОБЪЕМУ СЖАТОГО. В НАШЕМ СЛУЧАЕ ЭТО ОТНОШЕНИЕ РАВНО **$120/95 = 120/95 = 1,26$** .

НА САМОМ ДЕЛЕ ДАННОЕ СООБЩЕНИЕ В ПАМЯТИ КОМПЬЮТЕРА ЗАКОДИРОВАНО С ПОМОЩЬЮ ASCII, ПОЭТОМУ НА КАЖДЫЙ СИМВОЛ ОТВЕДЕНО 8 БИТ.

ТЕМ САМЫМ, ОБЪЕМ ИСХОДНОГО СООБЩЕНИЯ **240** БИТ, А КОЭФФИЦИЕНТ СЖАТИЯ СОСТАВЛЯЕТ $240/95 = 2,53$.

ИЗ ЭТОГО ВИДНО, КАКОЙ ВЫИГРЫШ МЫ ПОЛУЧИЛИ, ЕСЛИ ЭТО СООБЩЕНИЕ НУЖНО БЫЛО БЫ ПЕРЕДАТЬ ПО КАНАЛУ СВЯЗИ ИЛИ СОХРАНИТЬ НА КАКОМ-ЛИБО НОСИТЕЛЕ.

ДЛЯ ДЕКОДИРОВАНИЯ СЖАТОГО СООБЩЕНИЯ ВМЕСТЕ С НИМ ОБЫЧНО ПЕРЕСЫЛАЮТ НЕ КОДЫ ИСХОДНЫХ СИМВОЛОВ (Т.Е. ПЕРВЫЕ ДВЕ СТРОКИ), А САМ ОРГРАФ ХАФФМАНА (БЕЗ УКАЗАНИЯ ВЕСА КОРНЯ И РАЗМЕТКИ НА ДУГАХ, ИБО ОНА СТАНДАРТНА: ДУГА, ИДУЩАЯ ВЛЕВО, РАЗМЕЧАЕТСЯ -0, А ИДУЩАЯ ВПРАВО -1).

НА ЭТОМ, ОКАЗЫВАЕТСЯ, ТО ЖЕ МОЖНО СЭКОНОМИТЬ.

МАТЕМАТИКИ ДОКАЗАЛИ, ЧТО СРЕДИ АЛГОРИТМОВ КОДИРУЮЩИХ КАЖДЫЙ СИМВОЛ ПО ОТДЕЛЬНОСТИ И ЦЕЛЫМ КОЛИЧЕСТВОМ БИТ АЛГОРИТМ ХАФФМАНА ОБЕСПЕЧИВАЕТ НАИЛУЧШЕЕ

Используемая литература:

А.Г. Гейн. Математические основы информатики.

Педагогический университет «Первое сентября», 2008г.

<http://edu.1september.ru/courses/07/008/01.pdf>