ОСНОВЫ ПРОГРАММНОГО КОНСТРУИРОВАНИЯ

Лекция № 11

14 ноября 2016 г.

А ваши программы выглядят так же?

https://github.com/cypok/console_graphics

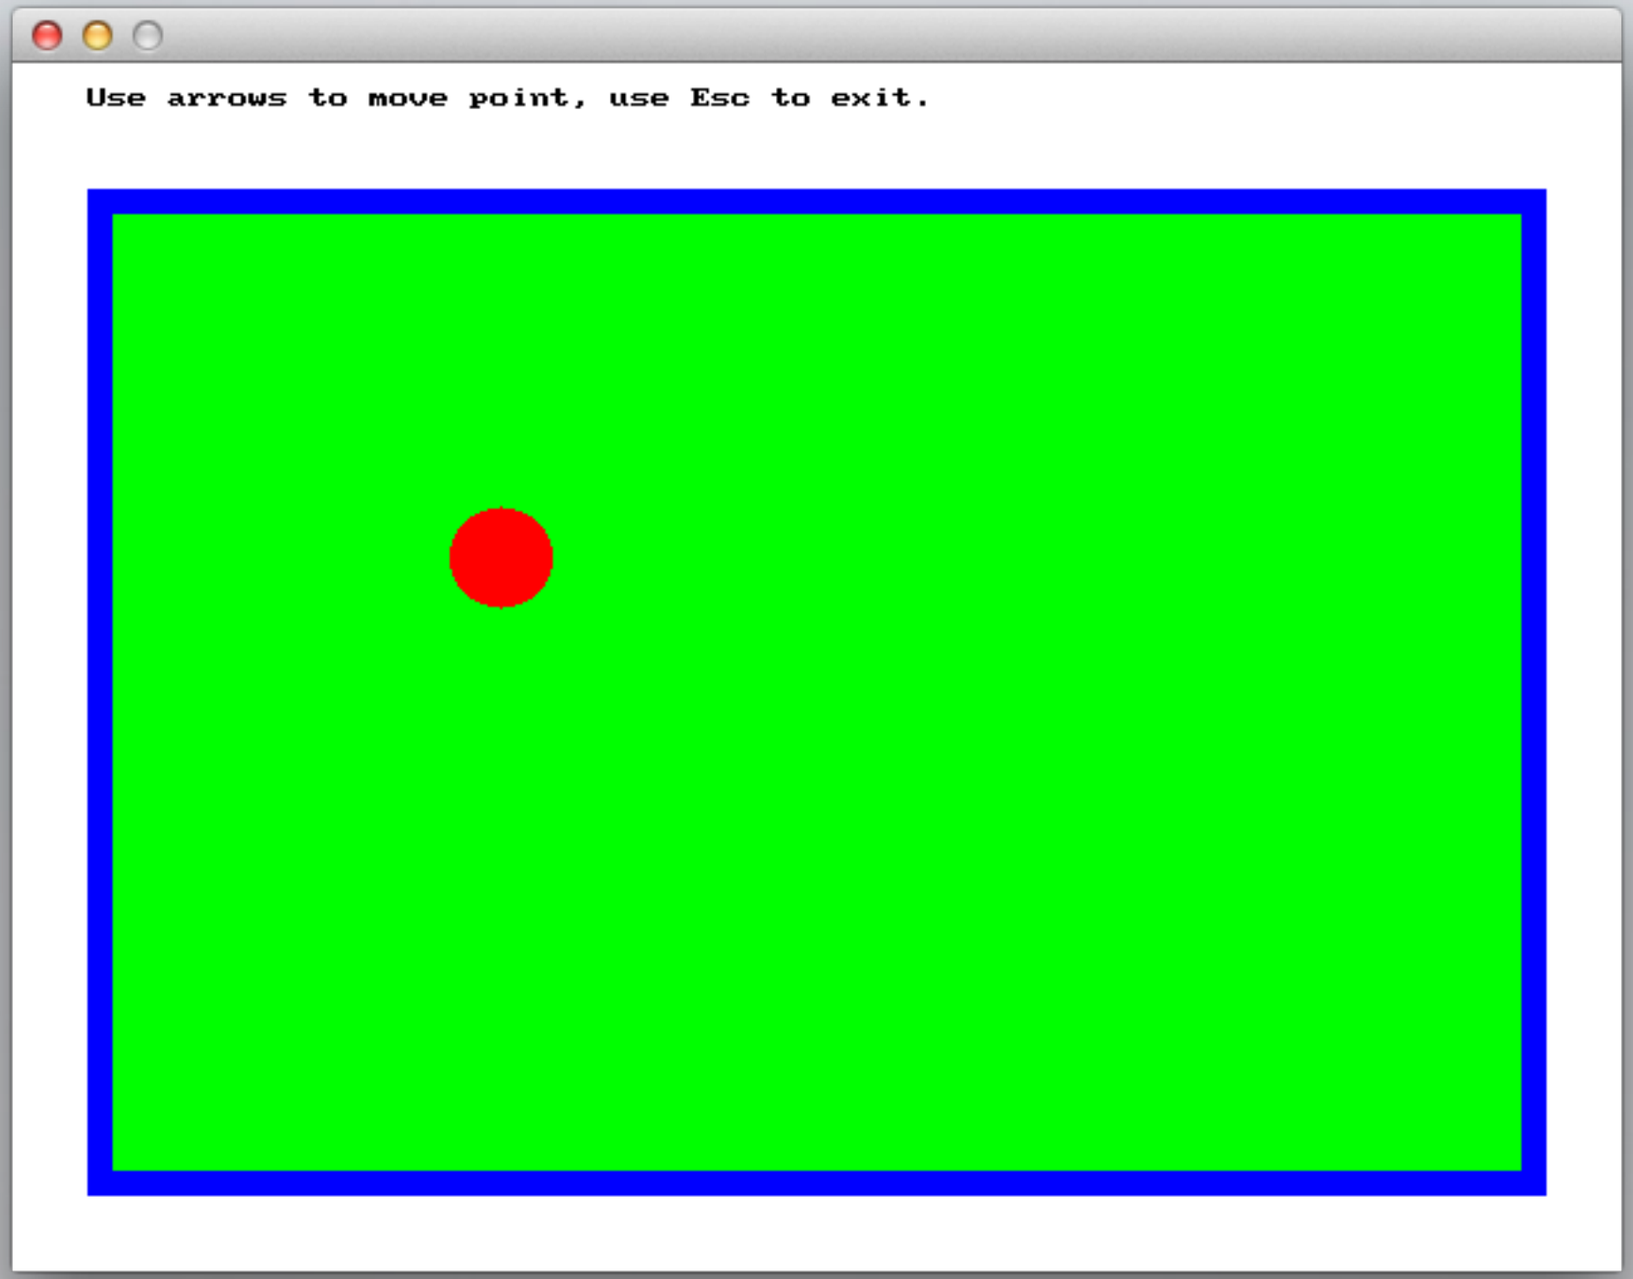

https://github.com/cypok/sdl_example

СЖАТИЕ (УПАКОВКА) ИНФОРМАЦИИ

- Принцип: сжимаем битовую цепочку за счет специфического кодирования.
- Обычные данные: T_1 = время доступа к данным.
- Сжатые данные:
  T_2 = время доступа к сжатым данным + время на распаковку.
- Часто $T_2 < T_1$!
- Чем меньше размер, тем больше скорость доступа.
- Иногда места действительно мало.

СЖАТИЕ БЕЗ ПОТЕРЬ

Возможно точное (бит-в-бит) восстановление исходной битовой цепочки.

СЖАТИЕ С ПОТЕРЯМИ

«А, все равно не видно (не слышно)…»
JPEG, MPEG и т.д.

ПРОГРАММА НА СЕГОДНЯ

Сжатие без потерь:

- Алгоритм RLE.
- Алгоритм Хаффмана.
- Алгоритм LZ77.
- Алгоритм LZW.

АЛГОРИТМ RLE

- Run-Length Encoding (сжатие повторяющихся цепочек). PCX, ILBM.
- Ч/б изображение: …**ББББББББЧББББЧЧББББЧЧЧЧЧЧЧ**…
- Упаковка: **9Б 1Ч 5Б 2Ч 5Б 9Ч**.
- Общий случай: выбирается редко используемый байт-префикс (**P**).
  - **XXXX → P 4 X**.
  - **X → X**.
  - **P P P P → P 4 P**.
  - **P → P 1 P**.

АЛГОРИТМ ХАФФМАНА

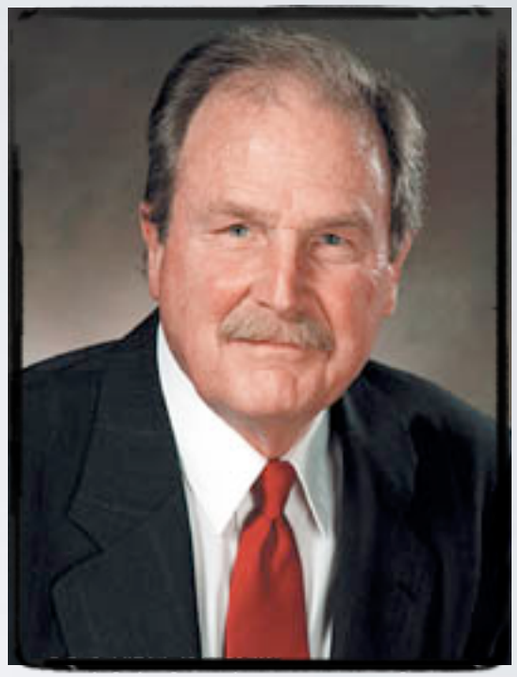

- В обычном файле все символы кодируются 8-битовыми цепочками, вне зависимости от частоты их появления.

- **Идея**: кодировать более часто встречающиеся символы более короткими цепочками.

- **Префиксные коды**: ни одна кодовое слово не является префиксом любого другого.

- Первый шаг: подсчет частоты вхождения символов в исходном файле.

ПРИМЕР КОДИРОВАНИЯ ПО ХАФФМАНУ

Символ	A	B	C	D	E	F
Частота вхождений	10	20	30	5	25	10

Сортируем по числу вхождений:

30 C | 25 E | 20 B | 10 F | 10 A | 5 D

ОБЪЕДИНЕНИЕ (ШАГ 1)

Два символа с минимальной частотой (A и D) формируют «суммарный» узел (*) с частотой 15.

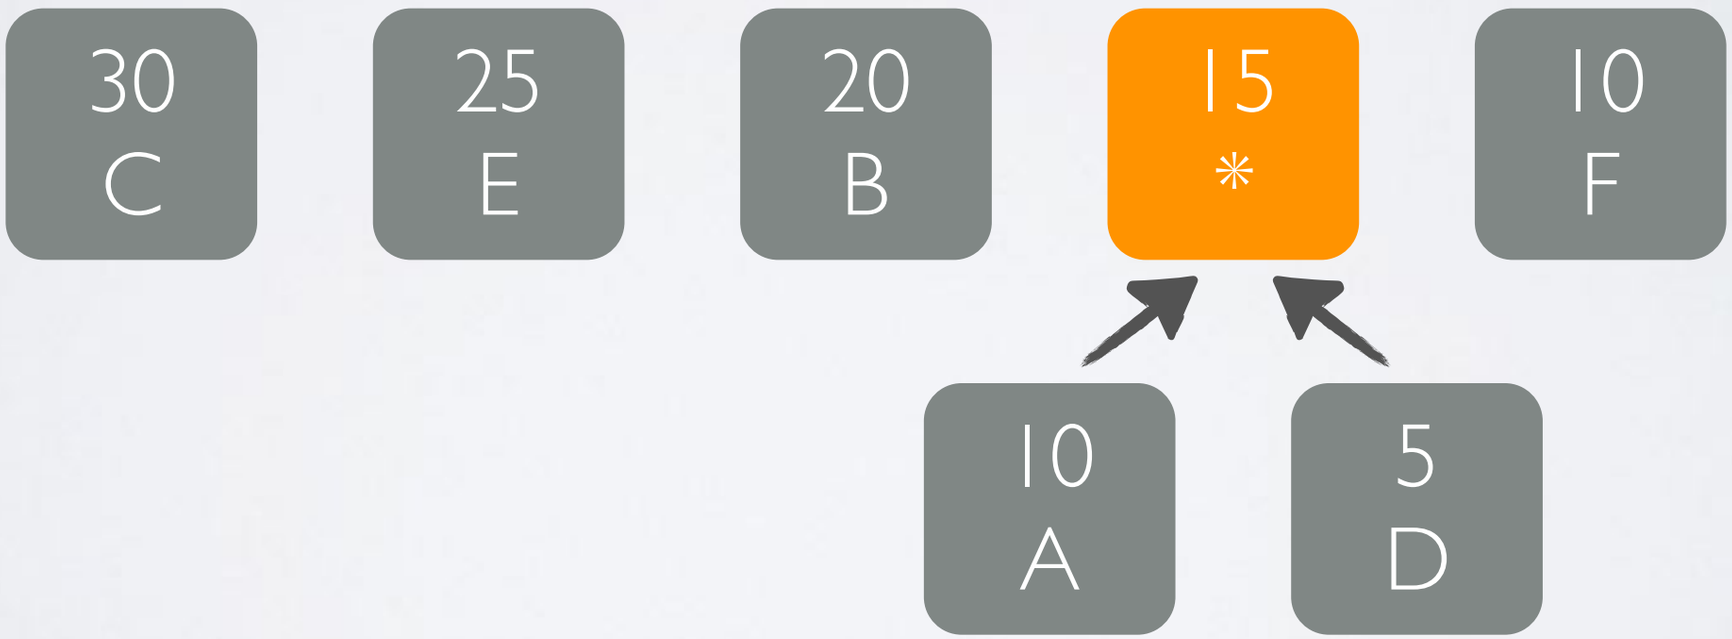

ОБЪЕДИНЕНИЕ (ШАГ 2)

Узлы F и * формируют узел ** (частота 25).

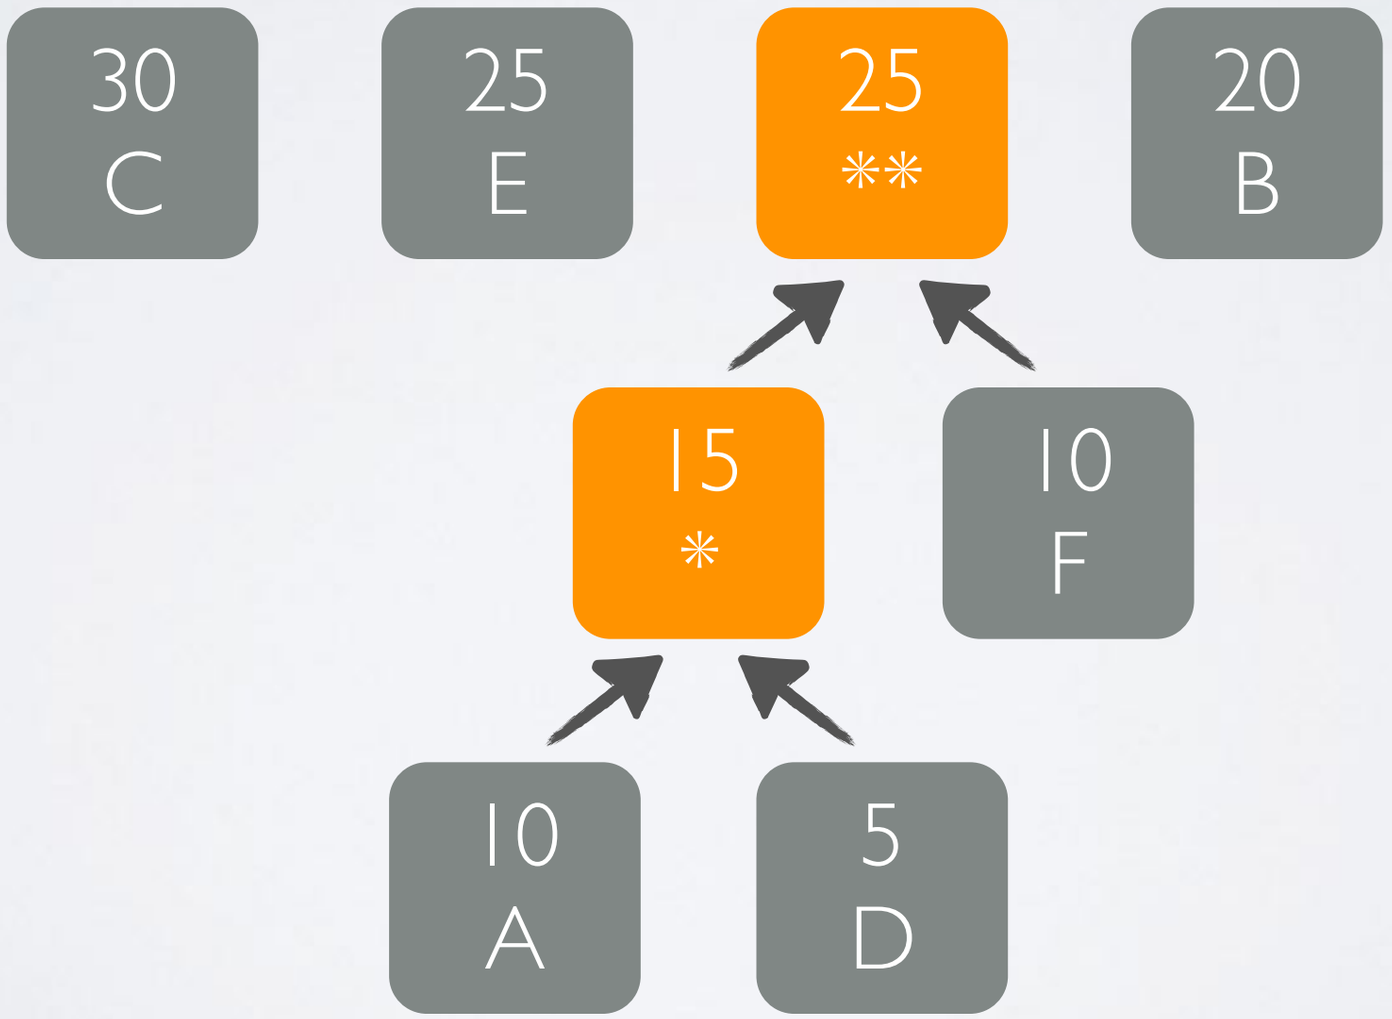

ОБЪЕДИНЕНИЕ (ШАГ 3)

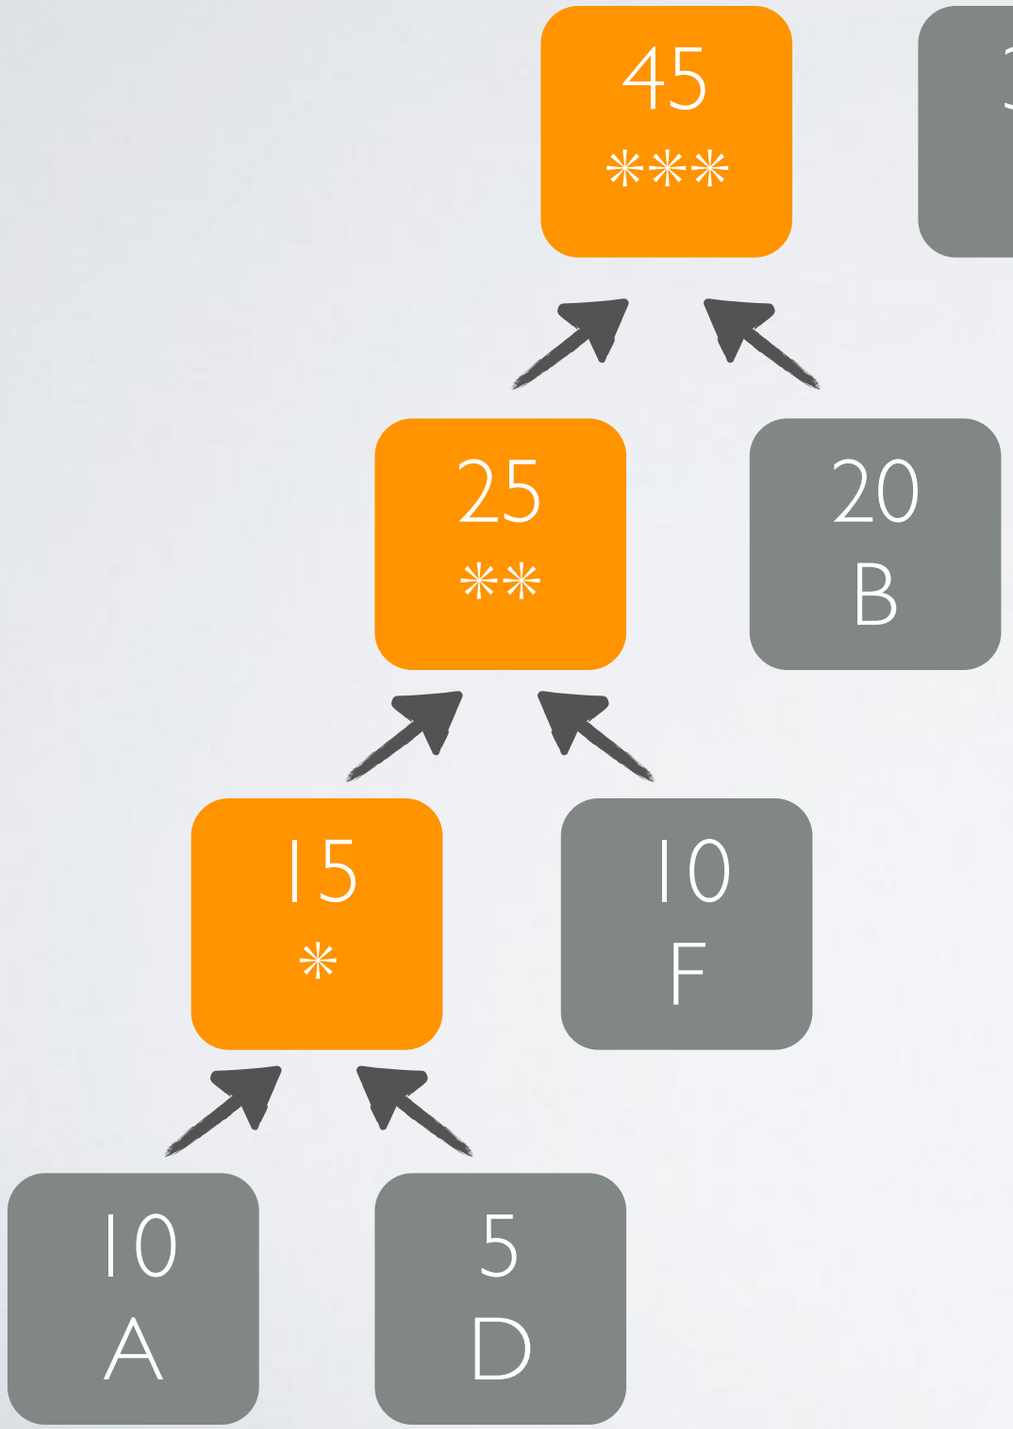

B и ** формируют *** (частота 45).

ОБЪЕДИНЕНИЕ (ШАГ 4)

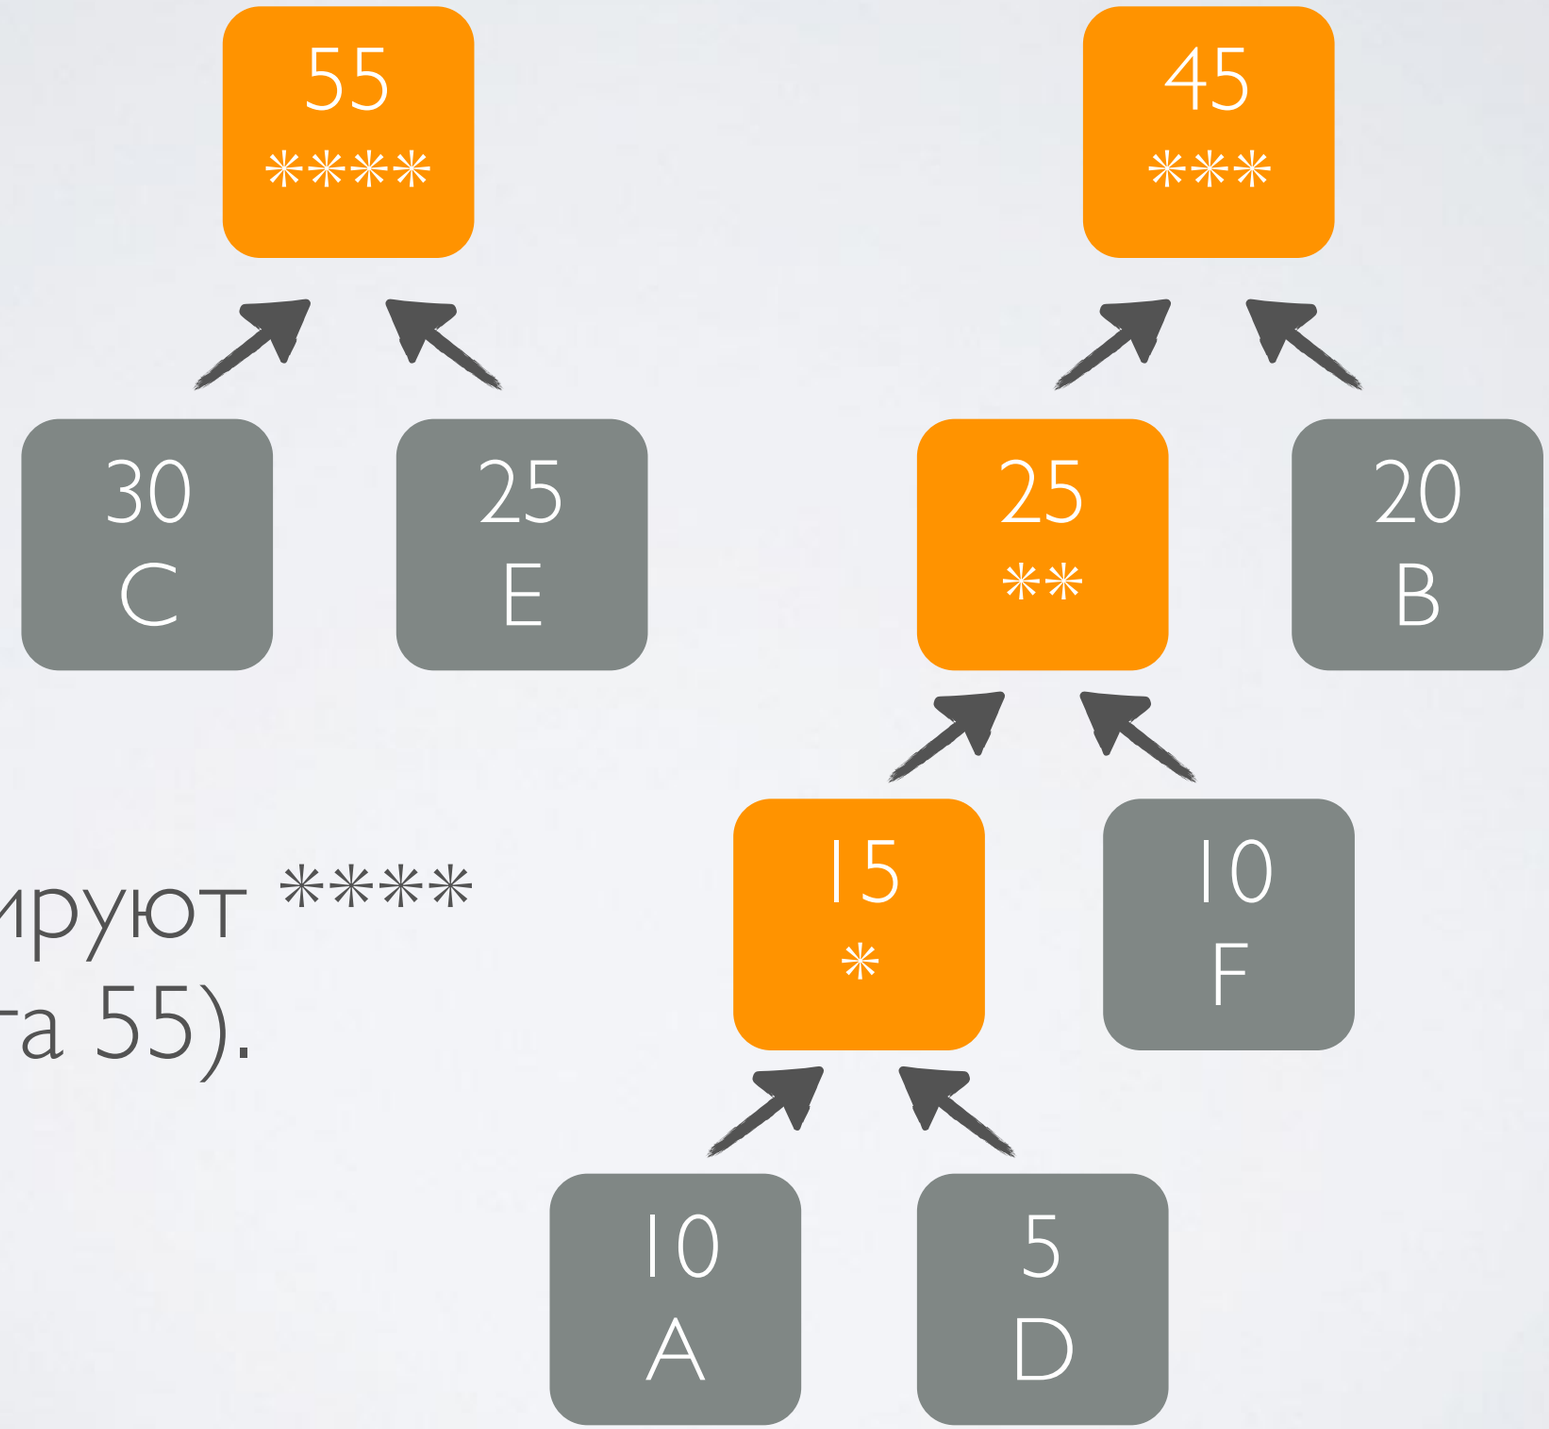

C и E формируют **** (частота 55).

ИТОГОВОЕ ДЕРЕВО

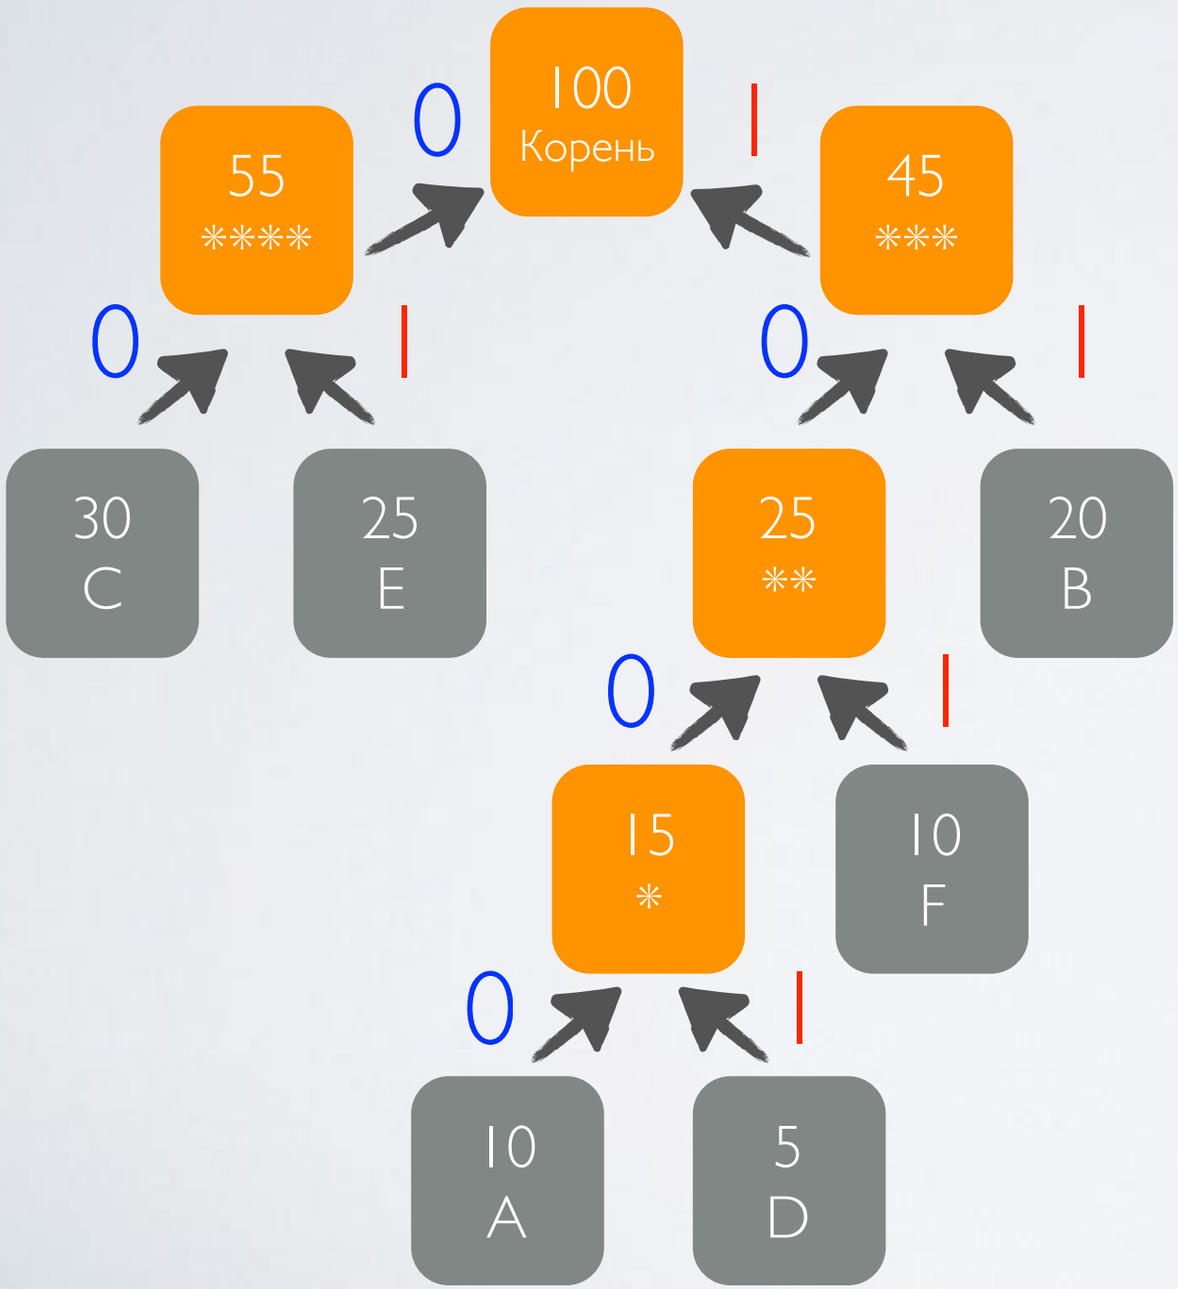

Символ	Частота	К. слово
C	30	00
E	25	01
B	20	11
F	10	101
A	10	1000
D	5	1001

КАНОНИЧЕСКИЙ КОД ХАФФМАНА

- Получившуюся таблицу кодов сортируем по парному ключу **(длина цепочки, ASCII код символа)**

- Первый символ: цепочка «все нули».

- Последующие символы: прибавляем 1 и дополняем нулями справа до нужной длины.

```
A = 1000
B = 11
C = 00
D = 1001
E = 01
F = 101
```

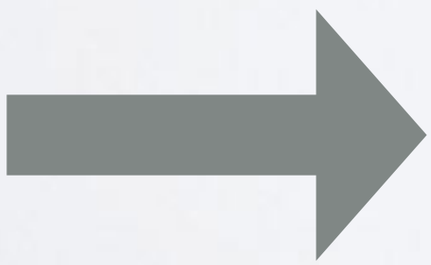

Сортировка

```
B = 11
C = 00
E = 01
F = 101
A = 1000
D = 1001
```

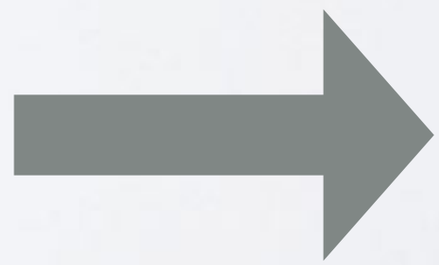

Перенумерация

```
B = 00
C = 01
E = 10
F = 110
A = 1110
D = 1111
```

РАСПАКОВКА

- Тривиальна при известном дереве (префиксные коды расшифровываются однозначно).

- Канонический код Хаффмана: дерево восстанавливается из таблицы соответствий «символ – длина кодового слова» при известной максимальной длине кода.

- Для упаковки массива длин размером 256 можно воспользоваться RLE.

НА СКОЛЬКО СЖАЛОСЬ?

- Было: 100 байт × 8 бит = 800 бит.
- Стало: (30+25+20) × 2 + 10 × 3 + (10+5) × 4 = 240 бит.
- Набор длин кодов: 6 букв × 2 бита + 16 (RLE) + 8 (макс. длина) = 36 бит.
- Итого: (240+36) / 800 = 34,5 %.

ПРОГРАММА НА СЕГОДНЯ

- ✓ Алгоритм RLE.
- ✓ Алгоритм Хаффмана.
- Алгоритм LZ77.
- Алгоритм LZW.

АЛГОРИТМ LZ77

Окно

- В окне ищется максимальная последовательность, соответствующая содержимому упреждающего буфера.
- В выходной поток пишется тройка (смещение, длина, след. символ в буфере).
- Окно сдвигается на длину найденной последовательности + 1.

ПРИМЕР LZ77

Исходные данные: «abracadabra».
Красным цветом отмечен буфер поиска.
Синим цветом отмечена совпадающаю последовательность.

Окно	Позиция	Длина	Символ
abracadabra	0	0	a
abracadabra	0	0	b
abracadabra	0	0	r
abracadabra	3	1	c
abracadabra	2	1	d
abracadabra	7	4	нет

Код: (0, 0, a), (0, 0, b), (0, 0, r), (3, 1, c), (2, 1, d), (7, 4, -)

ПРИМЕР LZ77

Исходные данные: «abababcab».
Красным цветом отмечен буфер поиска.
Синим цветом отмечена совпадающаю последовательность.

Окно	Позиция	Длина	Символ
abababcab	0	0	a
ababababcab	0	0	b
abababcab	2	4	c
abababcab	3	2	нет

Код: (0, 0, a), (0, 0, b), (2, 4, c), (3, 2, -)

АЛГОРИТМ LZW

- Заводим таблицу строк (например, размером 4096). Первые 256 кодов соответствуют символам ASCII.

- Алгоритм.

- Ищем с текущей позиции строку **s** максимальной длины, существующую в таблице.

- Выводим в файл индекс **s** в массиве (код).

- Если файл кончился, то выход, иначе добавляем в таблицу строку **s+c** (**c** – следующий символ) и устанавливаем текущую позицию на символ **c**.

ПРИМЕР LZW

XABCXABXABBXABBXABD

s	c	Выходной поток	Новые коды
X	A	X	256 = XA
A	B	A	257 = AB
B	C	B	258 = BC
C	X	C	259 = CX
XA	B	256	260 = XAB
B	X	B	261 = BX
XAB	B	260	262 = XABB
BX	A	261	263 = BXA
AB	B	257	264 = ABB
B	X	B	265 = BX
XAB	D	260	266 = XABD
D	Конец файла	D	нет

LZW РАСПАКОВКА

- Прочитать **Код$_0$** из файла и вывести **Таблица[Код$_0$]**.
- Пока входной поток не пуст:
  - читаем **Код$_1$** из файла;
  - выводим **Таблица[Код$_1$]**;
  - добавляем **Таблица[Код$_0$]** + ПервыйСимвол(**Таблица[Код$_1$]**);
  - заменяем **Код$_0$** ← **Код$_1$**.

ЕСТЬ ПРОБЛЕМА С РАСПАКОВКОЙ

- Пусть строка XYZ есть в таблице (код 333). Пусть далее: ……XYZXYZXYZ.

- **s**=XYZ, **c**=X, выводим 333, добавляем код 400=XYZX.

- На следующем шаге выводим код 400 (XYZX).

- Распаковщик увидит код 400 раньше, чем он определен.

- Решение: если считан неизвестный код, он будет соответствовать цепочке **Код$_0$** +ПервыйСимвол(**Код$_0$**).

СЖАТИЕ С ПОТЕРЯМИ

$$\hat{f}(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(x) e^{-ix\omega}\, dx$$

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N} kn}$$

$$y[n] = (x * g)[n] = \sum_{k=-\infty}^{\infty} x[k] g[n-k]$$

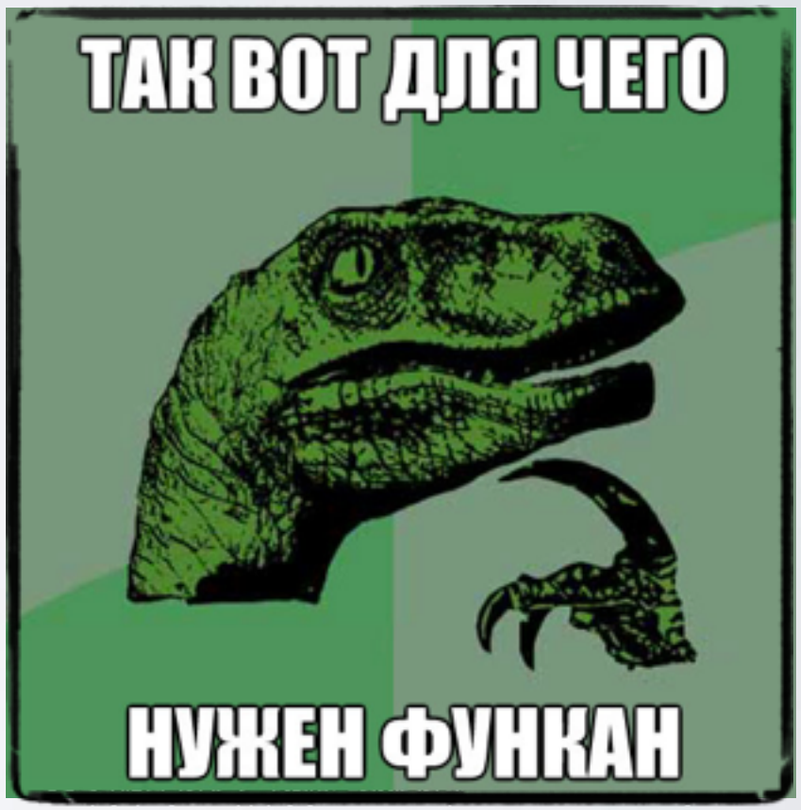

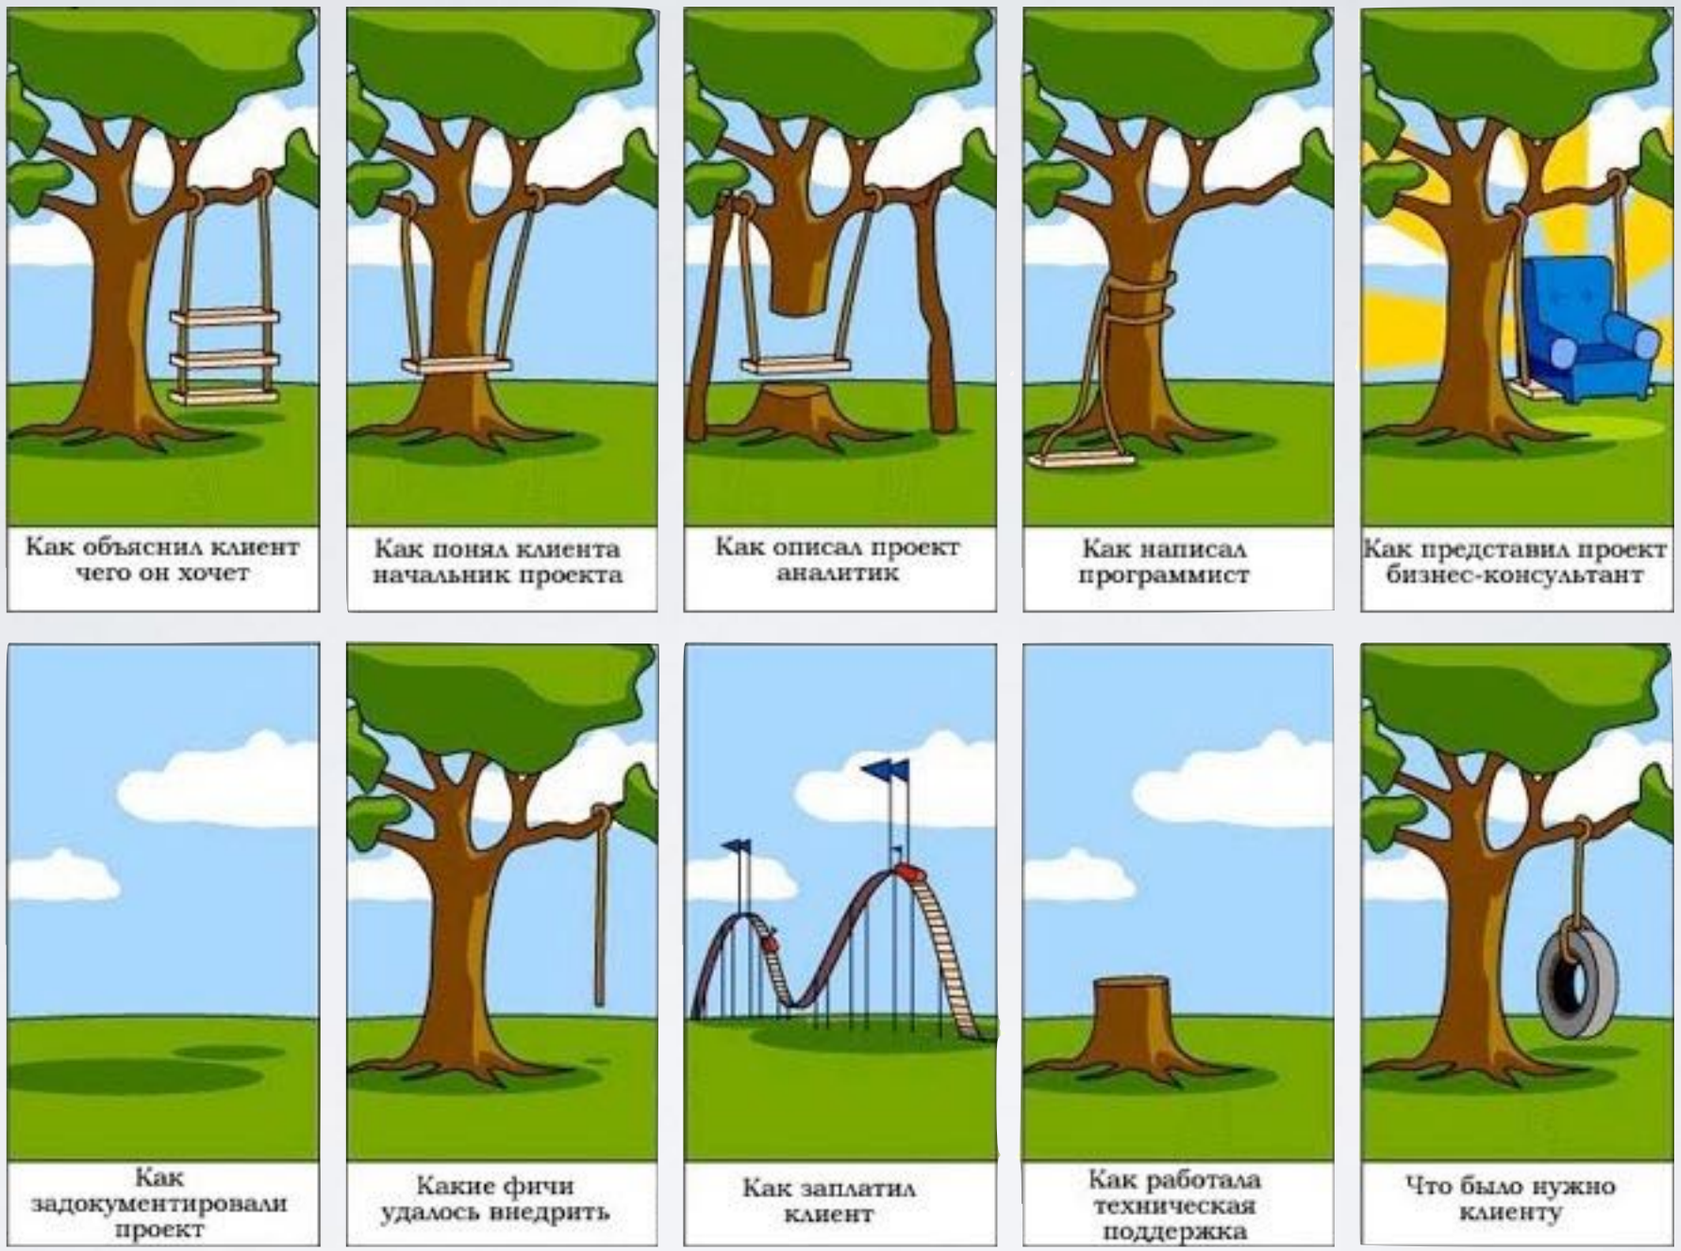

КОНЕЦ ОДИННАДЦАТОЙ ЛЕКЦИИ