

Лекция 0x11

6 апреля

Денормализованное число

- Условие: $\text{exp} = 000\dots0$
- Значение порядка: $E = -\text{Смещение} + 1$
(вместо $E = 0 - \text{Смещение}$)
- Мантисса кодируется с ведущим 0: $M = 0.\text{xxx}\dots x_2$
 - $\text{xxx}\dots x$: биты поля frac
- Примеры
 - $\text{exp} = 000\dots0, \text{frac} = 000\dots0$
 - Представляет число ноль
 - Различные кодировки для +0 и –0
 - $\text{exp} = 000\dots0, \text{frac} \neq 000\dots0$
 - Кодируются числа близкие к 0.0
 - Распределены по числовой прямой с равным шагом

Особые числа

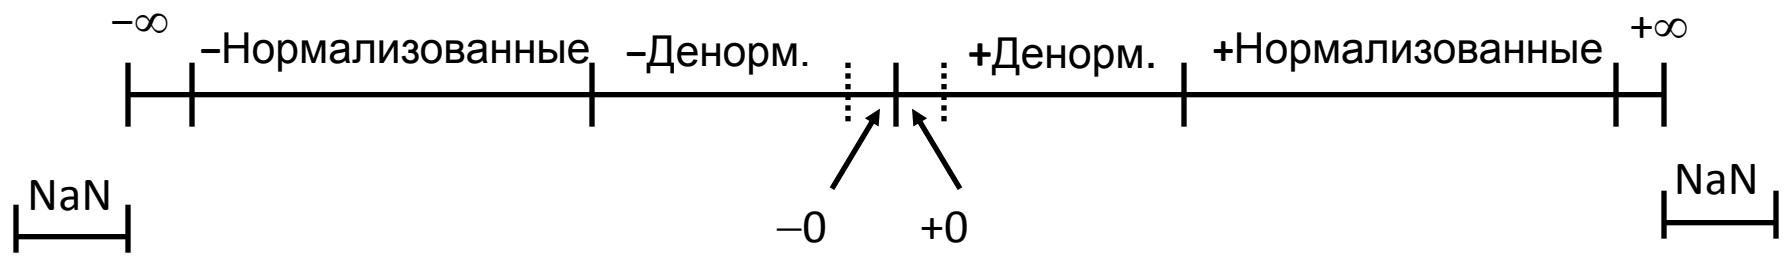
- Условие: $\text{exp} = 111\dots1$
- Пример: $\text{exp} = 111\dots1$, $\text{frac} = 000\dots0$
 - Представляет бесконечно большое число ∞
(как положительное, так и отрицательное)
 - Требуются для операций в которых может произойти переполнение
- Пример: $\text{exp} = 111\dots1$, $\text{frac} \neq 000\dots0$
 - Not-a-Number (NaN)
 - Используется в ситуациях, когда значение операции не определено

$\sqrt{-1}$

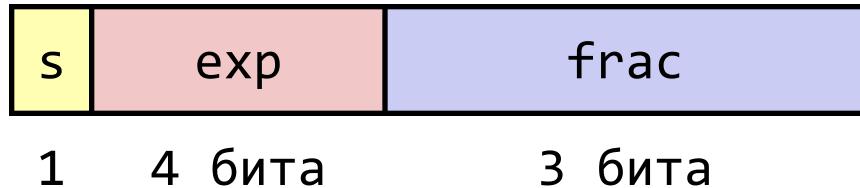
$\infty - \infty$

$\infty \times 0$

Диапазоны значений



Пример



- 8-разрядные числа с плавающей точкой
 - Знаковый бит – старший бит
 - Следующие четыре бита – порядок, смещение – 7
 - Последние три бита – дробная часть (мантиssa)
- Выполнены все требования стандарта IEEE 754 к формату числа
 - Реализованы нормализованные и денормализованные числа
 - Представлены значения 0, NaN, бесконечность

Диапазоны значений

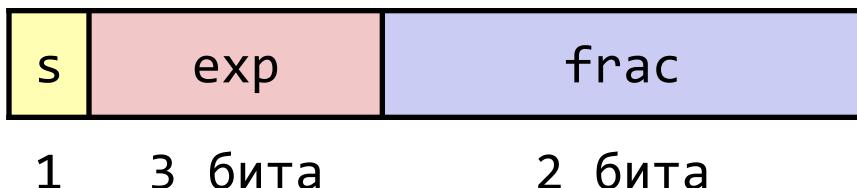
(только для положительных чисел)

	s	exp	frac	E	Значения	
Денормализованные числа	0	0000	000	-6	0	
	0	0000	001	-6	$1/8*1/64 = 1/512$	Ближайшее к 0
	0	0000	010	-6	$2/8*1/64 = 2/512$	
	...					
	0	0000	110	-6	$6/8*1/64 = 6/512$	
	0	0000	111	-6	$7/8*1/64 = 7/512$	Наибольшее денорм.
	0	0001	000	-6	$8/8*1/64 = 8/512$	Наименьшее норм.
	0	0001	001	-6	$9/8*1/64 = 9/512$	
	...					
	0	0110	110	-1	$14/8*1/2 = 14/16$	
Нормализованные числа	0	0110	111	-1	$15/8*1/2 = 15/16$	Ближайшее к 1 «снизу»
	0	0111	000	0	$8/8*1 = 1$	
	0	0111	001	0	$9/8*1 = 9/8$	Ближайшее к 1 «сверху»
	0	0111	010	0	$10/8*1 = 10/8$	
	...					
	0	1110	110	7	$14/8*128 = 224$	
	0	1110	111	7	$15/8*128 = 240$	Наибольшее норм.
	0	1111	000	n/a	inf	
	...					

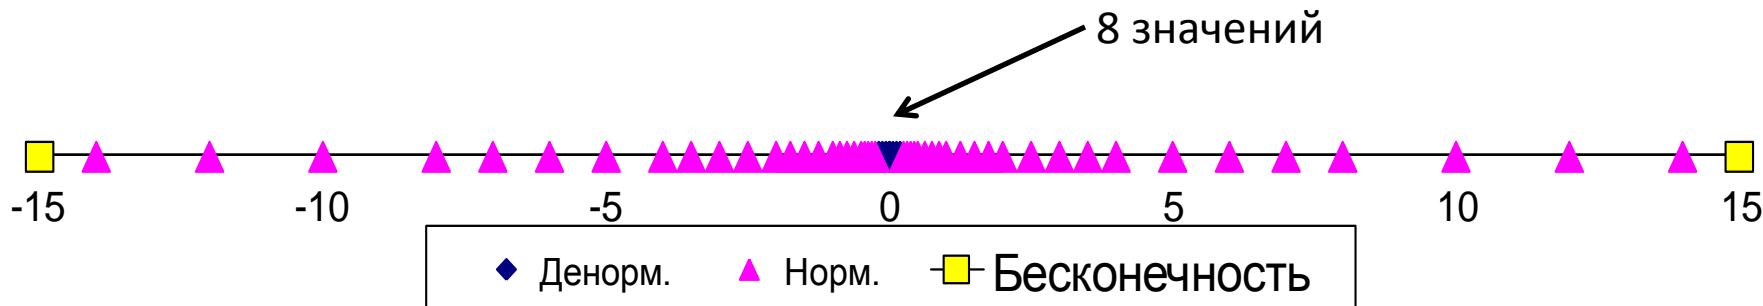
Распределение значений по числовой прямой

- 6-разрядный формат

- $e = 3$ бита порядка
- $f = 2$ бита мантиссы
- Смещение $2^{3-1}-1 = 3$

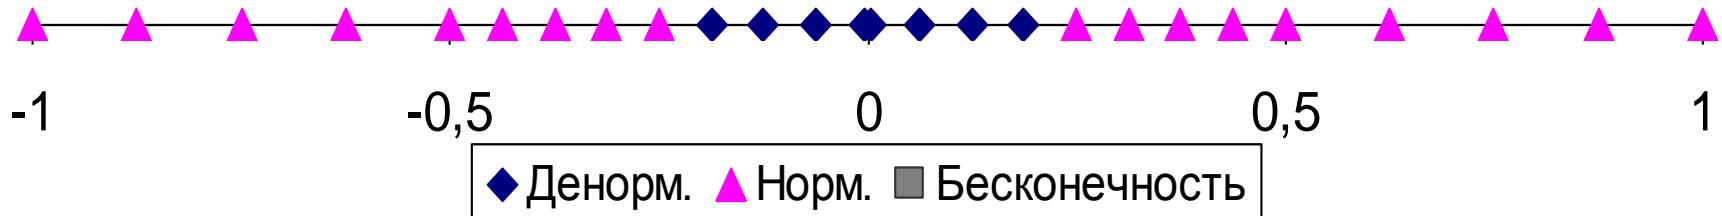
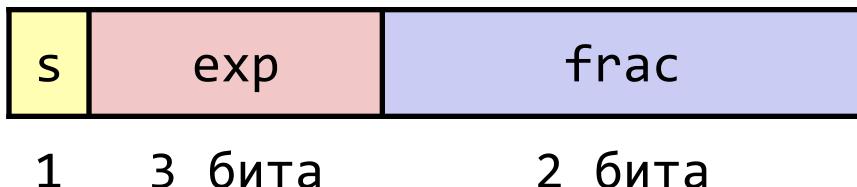


- Распределение сильно «сгущается» в окрестности 0



Распределение значений по числовой прямой (вид вблизи)

- 6-разрядный формат
 - $e = 3$ бита порядка
 - $f = 2$ бита мантиссы
 - Смещение 3



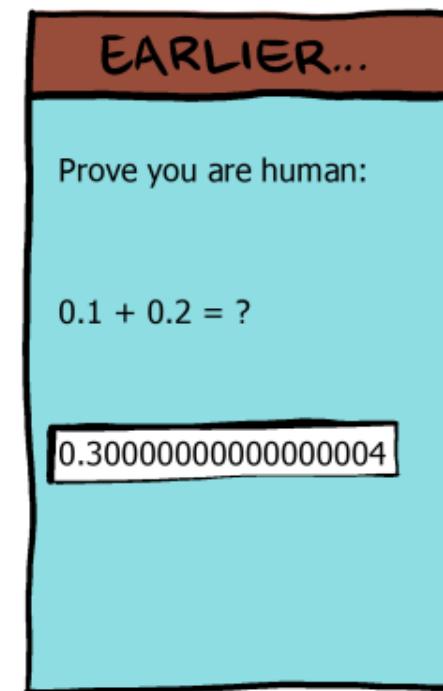
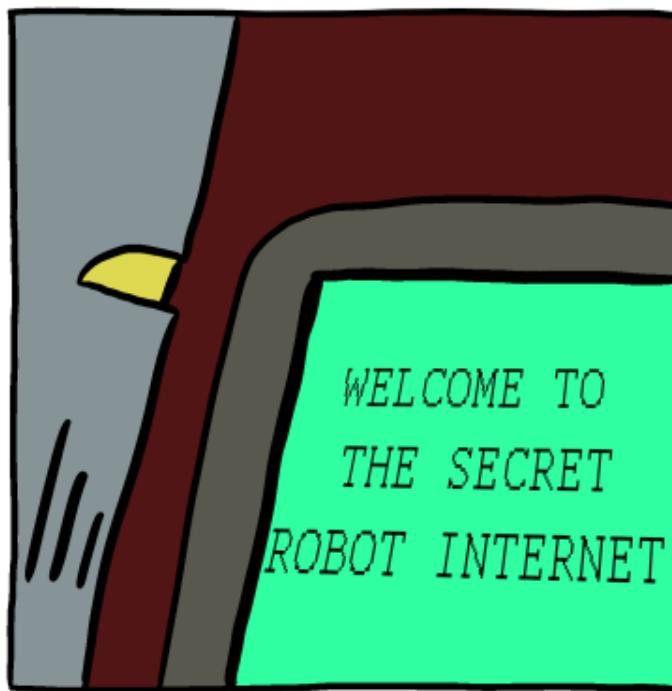
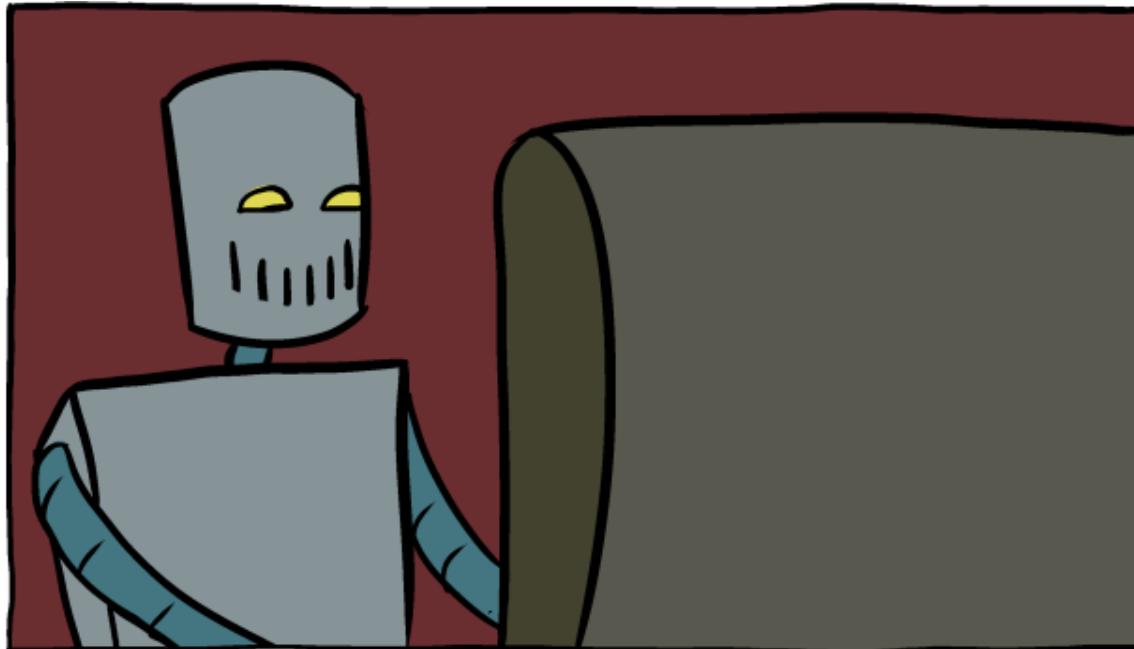
Некоторые числа

<i>Описание</i>	<i>exp</i>	<i>frac</i>	<i>Численное значение</i>
• Ноль	00...00	00...00	0.0
• Наименьшее «+» денорм.	00...00	00...01	$2^{-\{23,52\}} \times 2^{-\{126,1022\}}$
	– Одинарная точность $\approx 1.4 \times 10^{-45}$		
	– Двойная точность $\approx 4.9 \times 10^{-324}$		
• Наибольшее денорм.	00...00	11...11	$(1.0 - \varepsilon) \times 2^{-\{126,1022\}}$
	– Одинарная точность $\approx 1.18 \times 10^{-38}$		
	– Двойная точность $\approx 2.2 \times 10^{-308}$		
• Наименьшее «+» норм.	00...01	00...00	$1.0 \times 2^{-\{126,1022\}}$
	– Немногим больше чем наибольшее денормализованное		
• Единица	01...11	00...00	1.0
• Наибольшее норм.	11...10	11...11	$(2.0 - \varepsilon) \times 2^{\{127,1023\}}$
	– Одинарная точность $\approx 3.4 \times 10^{38}$		
	– Двойная точность $\approx 1.8 \times 10^{308}$		

Точность
 {одинарная, двойная}

Особенности кодировки

- FP ноль совпадает с целочисленным нулем
 - Все биты = 0
- Допустимо (в большинстве случаев) использовать беззнаковое целочисленное сравнение
 - Сперва сравниваем знаковые биты
 - Необходимо рассматривать $-0 = 0$
 - NaNs
 - В целочисленной интерпретации больше, чем любые другие числа
 - Что необходимо выдавать в качестве результата сравнения?
 - В противном случае ...
 - Денормализованные vs. Нормализованные
 - Нормализованные vs. Бесконечность



Округление

- Способы округления

	1.40	1.60	1.50	2.50	-1.50
– К нулю	1	1	1	2	-1
– К наименьшему ($-\infty$)	1	1	1	2	-2
– К наибольшему ($+\infty$)	2	2	2	3	-1
– К ближайшему (✓)	1	2	2	2	-2

Округление к ближайшему целому числу

- Основной способ округления
 - Все остальные способы дают статистическое смещение
 - Пример: суммирование положительных чисел будет давать устойчивую недо- или пере- оценку результата
- Применимо при округлении в произвольной позиции дроби
 - Когда число расположено точно посередине двух значений к которым можно округлить
 - Округляют к тому числу, у которого наименьшая значащая цифра четная
 - Например, округление до ближайших сотых

1.2349999 1.23

1.2350001 1.24

1.2350000 1.24 (середина — округляем к большему)

1.2450000 1.24 (середина — округляем к меньшему)

Округление двоичных чисел

- Двоичные дробные числа
 - “Четные” числа у которых младший значащий бит 0
 - “Середина” – когда биты справа от позиции к которой происходит округление = 100...₂
- Примеры
 - Округление до ближайшей 1/4 (2 бита справа от бинарной точки)

Число	Двоичное	Окр.	Действие	Окр. число
2 3/32	10.000 11 ₂	10.00 ₂	(<1/2—down)	2
2 3/16	10.00 110 ₂	10.01 ₂	(>1/2—up)	2 1/4
2 7/8	10.11 100 ₂	11.00 ₂	(1/2—up)	3
2 5/8	10.10 100 ₂	10.10 ₂	(1/2—down)	2 1/2

Умножение

- $(-1)^{s_1} M_1 2^{E_1} \times (-1)^{s_2} M_2 2^{E_2}$
- Точный результат: $(-1)^s M 2^E$
 - Знаковый бит s : $s_1 \wedge s_2$
 - Мантисса M : $M_1 \times M_2$
 - Порядок E : $E_1 + E_2$
- Исправление
 - Если $M \geq 2$, сдвигаем M вправо (делим на 2), увеличивая E
 - Если E выходит за пределы, переполнение
 - Округляем M до соответствующего размера поля `frac`

Сложение

- $(-1)^{s_1} M_1 2^{E_1} + (-1)^{s_2} M_2 2^{E_2}$

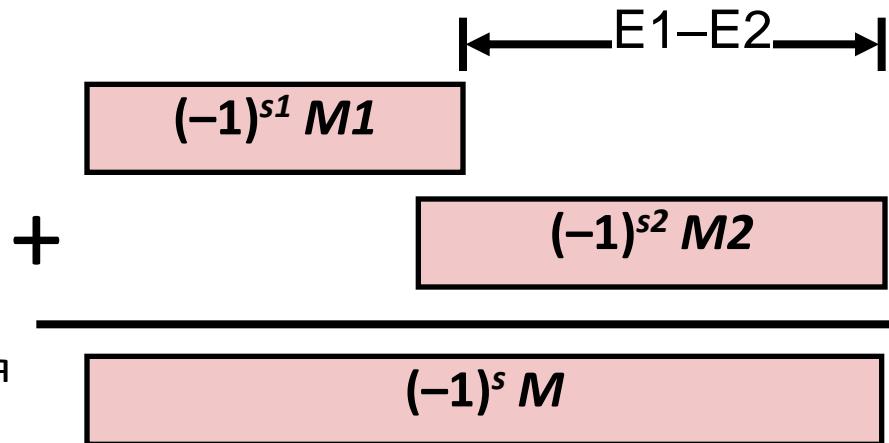
–Пусть $E_1 > E_2$

- Точный результат: $(-1)^s M 2^E$

–Знаковый бит s , мантисса M :

- Результат выравнивания и сложения

–Порядок E : E_1



- Исправление

–Если $M \geq 2$, сдвигаем M вправо, увеличивая E

–Если $M < 1$, сдвигаем M влево на k позиций, уменьшая E на k

–Переполнение если E выходит за пределы

–Округляем M до соответствующего размера поля *frac*

Математические свойства сложения

- Выполняются ли свойства Абелевых групп
 - Замкнутость?
 - Результатом может быть бесконечность или NaN
 - Коммутативность?
 - Да
 - Ассоциативность?
 - Переполнения и изменение результата при округлении
 - Да
 - 0..0 – нейтральный элемент?
 - Да
 - Каждый элемент имеет обратный
 - За исключением бесконечности и NaN
 - Нет
- Монотонность
 - $a \geq b \Rightarrow a+c \geq b+c?$
 - За исключением бесконечности и NaN
 - Почти всегда

Математические свойства умножения

- Выполняются ли свойства коммутативных колец
 - Замкнуто ли относительно умножения? Да
 - Результат может быть бесконечность или NaN
 - Умножение коммутативно? Да
 - Умножение ассоциативно?
 - Возможность переполнения, неточности округления
 - 1.0 – мультипликативная единица? Да
 - Умножение дистрибутивно над сложением?
 - Возможность переполнения, неточности округления
- Монотонность
 - $a \geq b \ \& \ c \geq 0 \Rightarrow a * c \geq b * c?$
 - Исключение – бесконечность и NaN

Почти
всегда

Числа с плавающей точкой в языке Си

- Язык Си вводит два уровня точности
 - `float` одинарная точность
 - `double` двойная точность
- Приведение типа
 - Приведение типа между `int`, `float`, и `double` включает изменение битового представления
 - `double/float → int`
 - Отбрасывается дробная часть (аналогично округлению к нулю)
 - Поведение не определено, когда значение вне допустимого диапазона или `NaN`: как правило устанавливается `TMin`
 - `int → double`
 - Точное приведение, поскольку `long` и `int` 32 бита \leq 53 бита
 - `int → float`
 - Будет округляться согласно принятым соглашениям

Задачи

- Для каждого Си-выражения объяснить:
 - почему оно верно для любого значения переменных, ...
 - ... либо почему ложно

```
int x = ...;
float f = ...;
double d = ...;
```

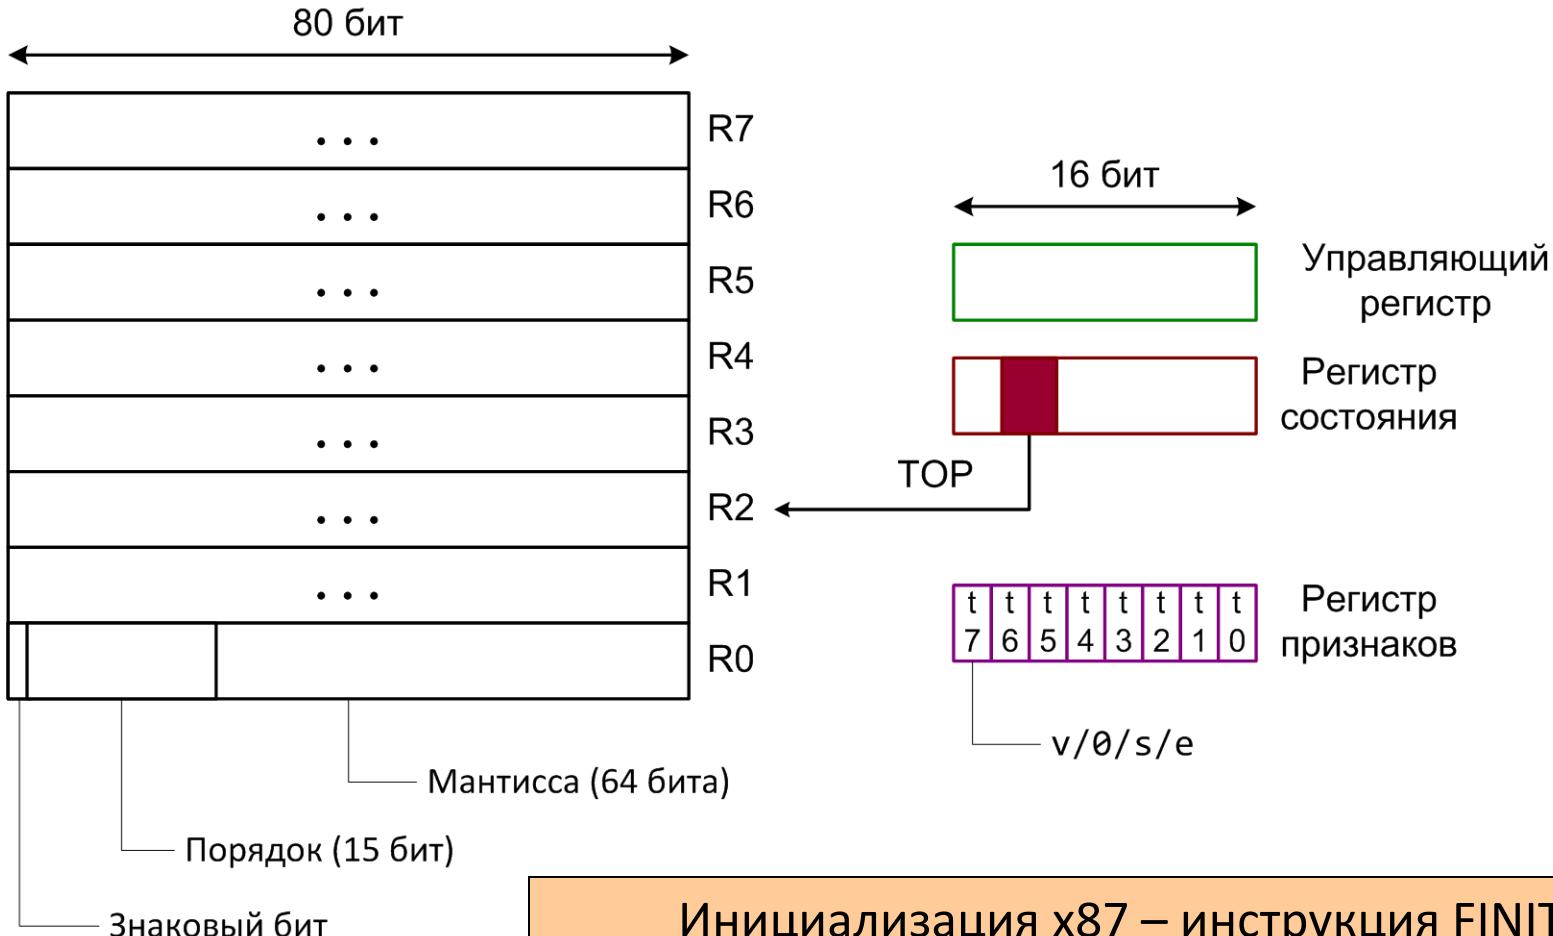
Предполагается, что
d и f не являются NaN

- $x == (\text{int})(\text{double}) x$
- $x == (\text{int})(\text{float}) x$
- $f == (\text{float})(\text{double}) f$
- $d == (\text{float}) d$
- $f == -(-f);$
- $2/3 == 2/3.0$
- $d < 0.0 \Rightarrow ((d*2) < 0.0)$
- $d > f \Rightarrow -f > -d$
- $d * d >= 0.0$
- $(d+f)-d == f$

Числа с плавающей точкой: промежуточные итоги

- IEEE 754 – четкое определение математических свойств
- Представляются числа вида $M \times 2^E$
- Семантика операций не зависит от особенностей аппаратуры
 - Сперва точное вычисление, затем округление
- Отличия от «настоящей» арифметики
 - Нарушаются свойства ассоциативности и дистрибутивности
 - Создаются сложности для компилятора и серьезных математических вычислений

Упрощенная схема x87



Инициализация x87 – инструкция FINIT

CW = 0x037F SW = 0x0000 Tag = 0xFFFF

Размер чисел с плавающей точкой

Регистры данных

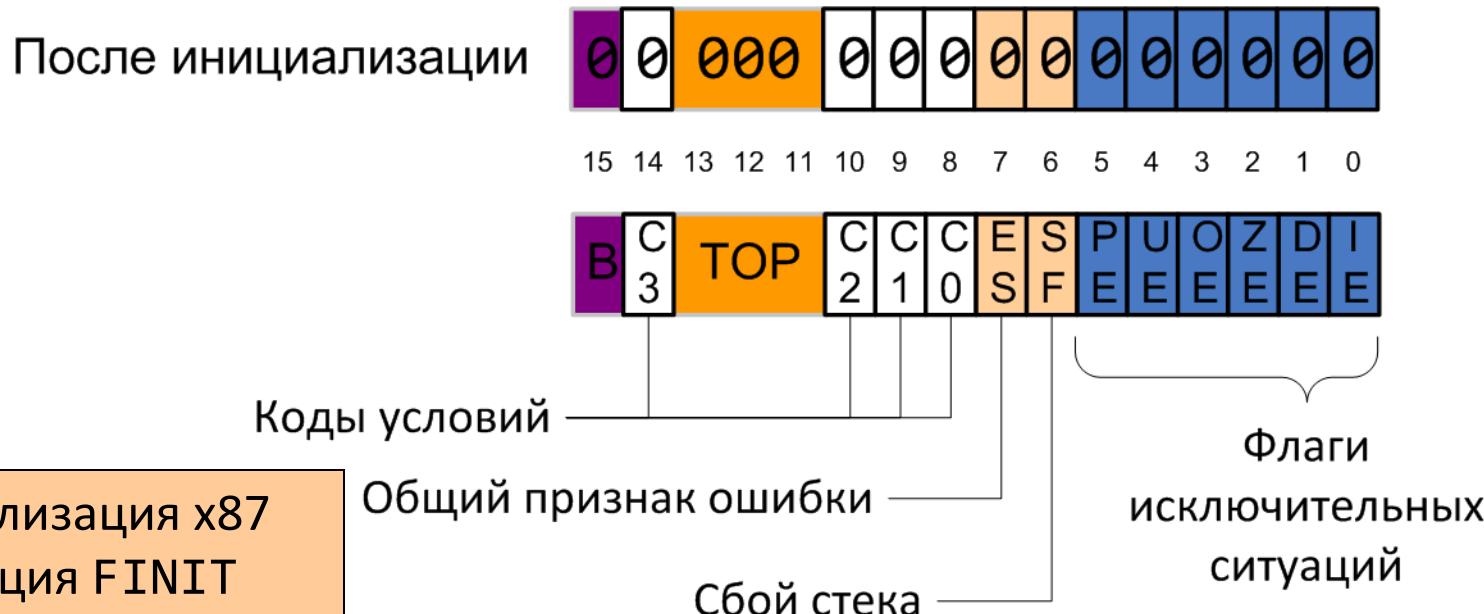
Знак	79	78	64	63		0
R7	Порядок		Мантисса			
R6						
R5						
R4						
R3						
R2						
R1						
R0						

Обмен данными только с памятью!

```
dd 1.234567e20 ; Константы одинарной точности
dq 1.234567e20 ; Двойной точности
dt 1.234567e20 ; Расширенной точности
```

Слово (регистр) состояния

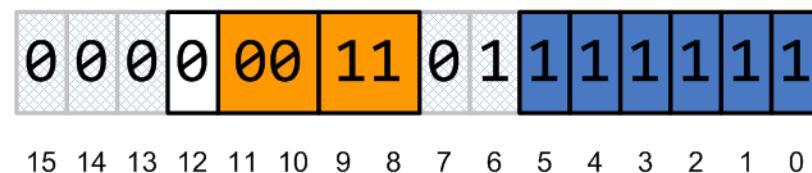
- SF – переполнение стека (C1 показывает направление)
- Исключительные ситуации: точность, переполнение, деление на ноль, денормализованный операнд, «неправильные» данные



Управляющий регистр

- Точность: одинарная, двойная, расширенная
- Округление: к ближайшему четному, к нулю, к +/- бесконечности
- Флаг X – совместимость с 287
- Маски соответствуют исключениям в слове состояния

После инициализации



Округление

Точность

Маски флагов
исключительных
ситуаций

Инициализация x87
инструкция FINIT
CW = 0x037F

Регистр признаков (тагов)

- Состояние регистров
 - 0 – нормализованное число с плавающей точкой
 - 1 – число ноль
 - 2 – особые числа (NaN , $\pm \infty$, денормализованное число)
 - 3 – регистр свободен
- Нумерация соответствует физическим регистрам

После инициализации



15

0



Инициализация x87
инструкция FINIT

Tag = 0xFFFF

NASM и числа с плавающей точкой

```

db -0.2          ; «Четверть»
dw -0.5          ; IEEE 754r/SSE5
                  ; половинная точность
dd 1.2           ; одинарная точность
dd 1.222_222_222 ; допускается использовать
                  ; знак подчеркивания
dd 0x1p+2        ; 1.0x2^2 = 4.0
dq 0x1p+32        ; 1.0x2^32 = 4 294 967 296.0
dq 1.e10          ; 10 000 000 000.0
dq 1.e+10         ; синоним для 1.e10
dq 1.e-10         ; 0.000 000 000 1
dt 3.141592653589793238462 ; число Пи
do 1.e+4000        ; IEEE 754r четверная точность

```

__float8__
 __float16__
 __float32__
 __float64__
 __float80m__
 __float80e__
 __float128l__
 __float128h__

__Infinity__
 __NaN__
 __QNaN__
 __SNaN__

IEEE 754r – опубликован в 2008 году

```

dq +1.5, -__Infinity__, __NaN__
mov eax, __float32__(3.1415926)

```

Сложение двух чисел

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .text
global CMAIN
```

```
CMAIN:
finit
fld dword [x]
fld dword [y]
faddp
fstp dword [z]
PRINT_HEX 4, z
NEWLINE
xor eax, eax
ret
```

x

11.2 ~ 1.119999980926513671875E1

0x41333333 = 01000001 00110011 00110011 00110011

Сложение двух чисел

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .text
global CMAIN
```

```
CMAIN:
finit
fld dword [x]
fld dword [y]
faddp
fstp dword [z]
PRINT_HEX 4, z
NEWLINE
xor eax, eax
ret
```

у

0.7 ~ 6.9999998079071044921875E-1

0x3F333333 = 00111111 00110011 00110011 00110011

Сложение двух чисел

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .text
global CMAIN
```

```
CMAIN:
finit
fld dword [x]
fld dword [y]
faddp
fstp dword [z]
PRINT_HEX 4, z
NEWLINE
xor eax, eax
ret
```

z

0x413E6666 = 0100001 00111110 01100110 01100110

1.18999996185302734375E1 ~ 11.9

Печать числа

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .rodata
lc db '%f', 10, 0

section .text
CEXTERN printf
global CMAIN
```

```
CMAIN:
; ...
; пролог функции
sub esp, 20

fld dword [x]
fld dword [y]
faddp
fst dword [z]
fstp dword [esp + 4]
mov dword [esp], lc
call printf

add esp, 20
; эпилог функции
; ...
```

Печать числа

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .rodata
lc db '%f', 10, 0

section .text
CEXTERN printf
global CMAIN
```

CMAIN:

; ...

; пролог функции

sub esp, 20

fld dword [x]

fld dword [y]

faddp

fst dword [z]

fstp dword [esp + 4]

mov dword [esp], lc

call printf

add esp, 20

; эпилог функции

; ...

printf печатает мусор
где ошибка?!?!!1

Печать числа

```
%include 'io.inc'

section .data
x dd 11.2
y dd 0.7

section .bss
z resd 1

section .rodata
lc db '%f', 10, 0

section .text
CEXTERN printf
global CMAIN
```

CMAIN:

; ...

; пролог функции

sub esp, 20

fld dword [x]

fld dword [y]

faddp

fst dword [z]

fstp **qword** [esp + 4]

mov dword [esp], lc

call printf

add esp, 20

; эпилог функции

; ...

ISO/IEC 9899:1999

§ 6.5.2.2 абзац №6