Linux вам не компилятор: ускоряем eBPF в полтора раза с помощью LLVM

Илья Гладышев

В этом докладе

- Устройство eBPF на данный момент
  - Байткод и его компиляция
  - Где спрятаны неоптимальности

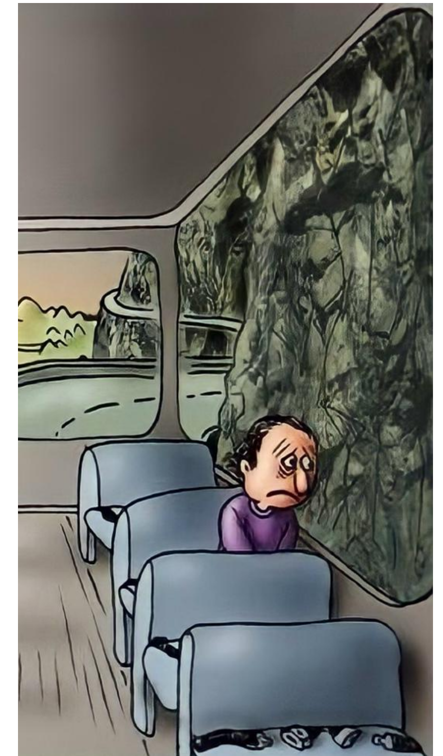

В этом докладе

- Устройство eBPF на данный момент
  - Байткод и его компиляция
  - Где спрятаны неоптимальности

- Как притащить LLVM
  - Архитектура и нюансы
  - Результаты

Что такое eBPF

- Виртуальная машина внутри ядра
  - “Реактивные” расширения (хуки, фильтры)
- Удобное взаимодействие с userspace (maps)
- Гарантируется отсутствие UB
  - Детерминированное исполнение
  - Изоляция багов

Примеры eBPF

- sched_ext
  - Планировщики CPU на eBPF
  - Эксперименты Meta с topology-aware scheduling
- Cilium
  - Сетевой стек для Kubernetes
  - Pod-to-pod, load balancing, …
  - Полностью в eBPF, “минуя” ядро

Пишем XDP фильтр

```c
const int MIN_SIZE = 100;

SEC("xdp")
int xdp_pass(struct xdp_md *ctx) {
    void *end = (void *)(long)ctx->data_end;
    void *data = (void *)(long)ctx->data;

    if (end - data < MIN_SIZE) {
        return XDP_DROP;
    }

    return XDP_PASS;
}
```

Пишем XDP фильтр

```
const volatile int MIN_SIZE = 100;

SEC("xdp")
int xdp_pass(struct xdp_md *ctx) {
    void *end = (void *)(long)ctx->data_end;
    void *data = (void *)(long)ctx->data;

    if (end - data < MIN_SIZE) {
        return XDP_DROP;
    }

    return XDP_PASS;
}
```

MIN_SIZE читается из .rodata

Можем менять без компиляции

Виртуальная машина eBPF

- 64-битная RISC архитектура
- 10 регистров + stack pointer
- Двухоперандные инструкции

R0	Возврат
R1-R5	Аргументы
R6-R9	Callee-saved
R10	Stack pointer

Виртуальная машина eBPF

- ✓ABI совместимо с основными архитектурами
  - Не требуется конвертация
- ✓Просто верифицировать

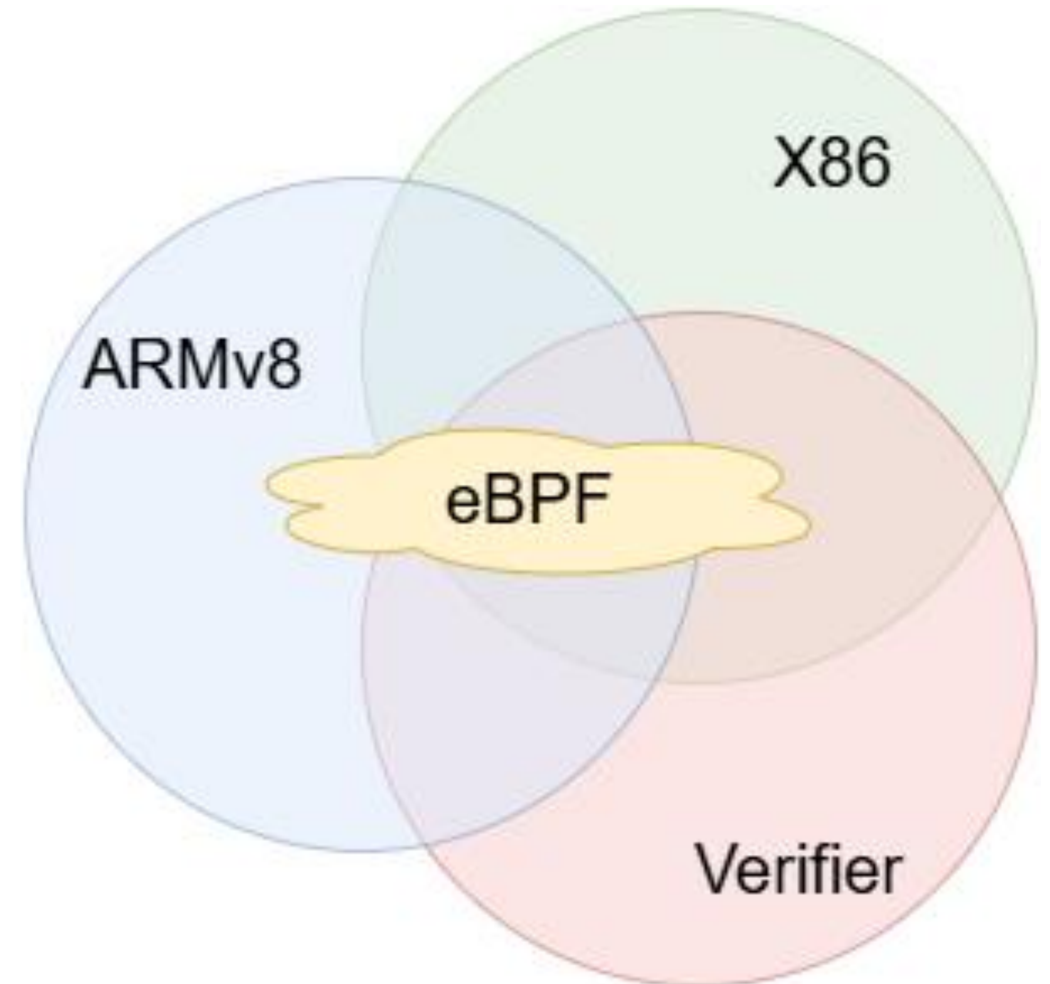

Виртуальная машина eBPF

- ✓ABI совместимо с основными архитектурами
  - Не требуется конвертация
- ✓Просто верифицировать

- ×Все архитектуры отображены одинаково плохо

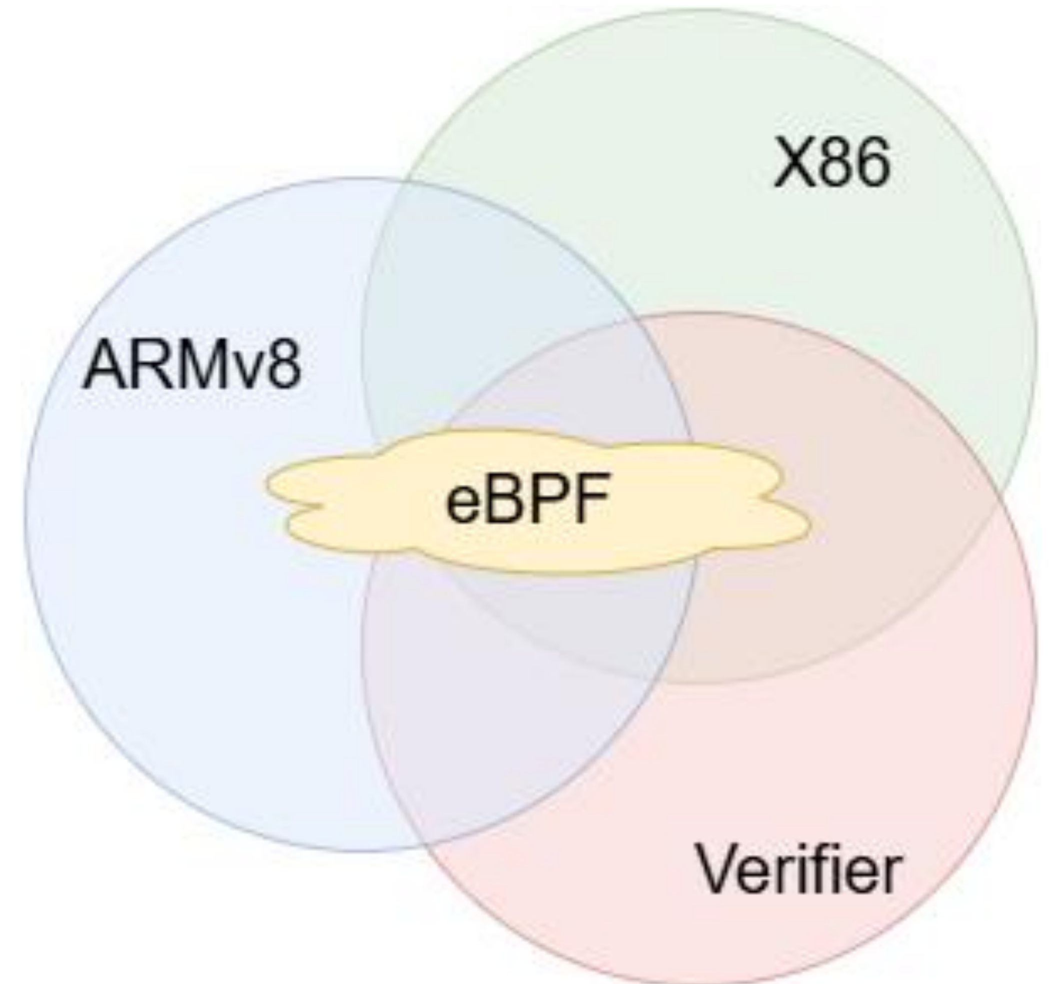

Пишем XDP фильтр

```
const volatile int MIN_SIZE = 100;

SEC("xdp")
int xdp_pass(struct xdp_md *ctx) {
    void *end = (void *)(long)ctx->data_end;
    void *data = (void *)(long)ctx->data;

    if (end - data < MIN_SIZE) {
        return XDP_DROP;
    }

    return XDP_PASS;
}
```

```
xdp_pass:
        w2 = *(u32 *)(r1 + 0)
        w1 = *(u32 *)(r1 + 4)
        r1 -= r2
        r2 = MIN_SIZE ll
        w2 = *(u32 *)(r2 + 0)
        r2 <<= 32
        r2 s>>= 32
        w0 = 1
        if r1 s< r2 goto LBB0_2
        w0 = 2
LBB0_2:
        exit
```

```
clang -target ebpf xdp.c -o xdp.bpf.o
```


https://godbolt.org/z/xMhTK1rhr

Загрузка eBPF

ELF

libbpf

bpf()

XDP

int xdp_pass(ctx)

.rodata

int MINSIZE

meta

symtab / rel

Загрузка eBPF

- Собирает функции в программы

Загрузка eBPF

ELF

libbpf

bpf()

- Собирает функции в программы

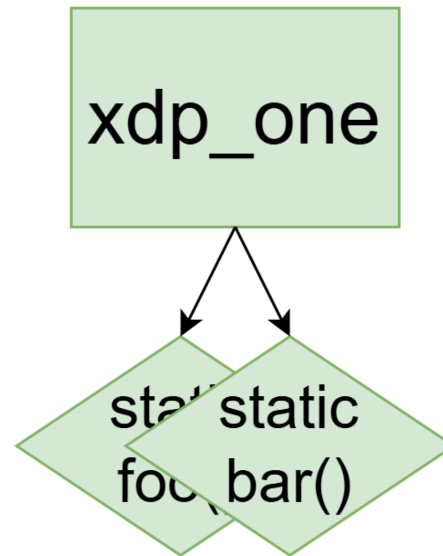

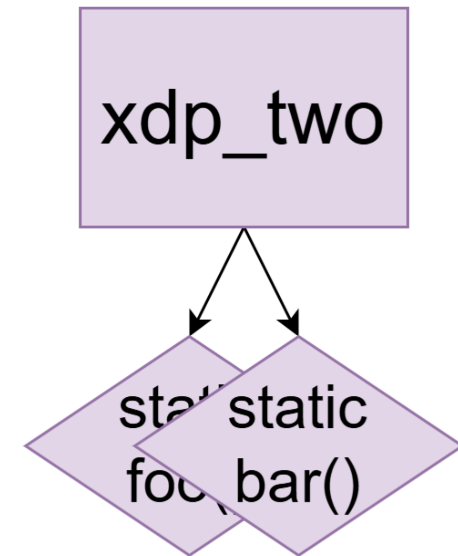

Загрузка eBPF

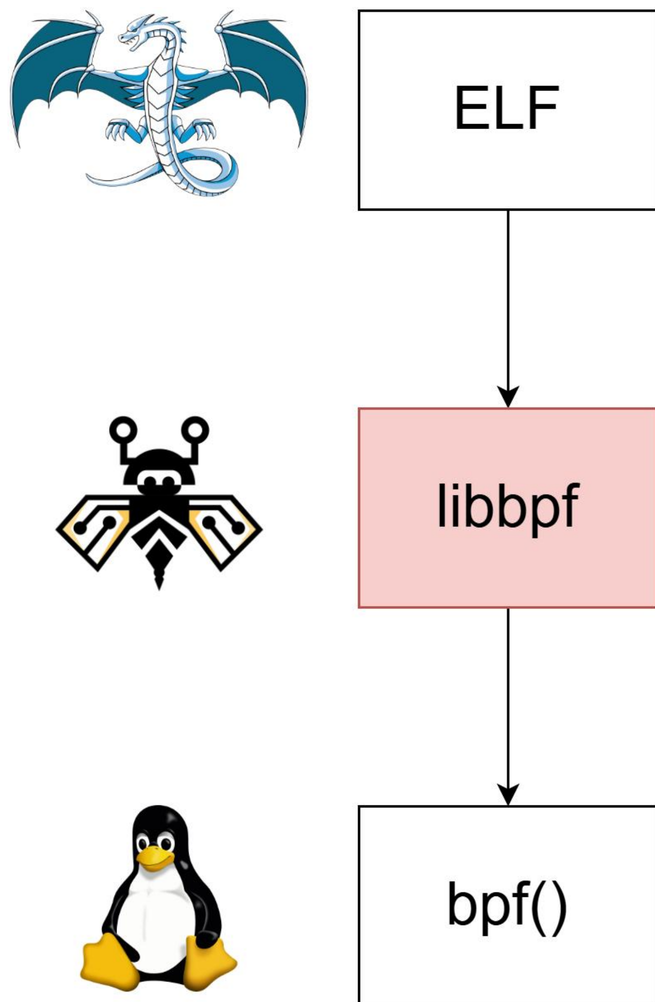

- Собирает функции в программы
- Конвертирует rodata в eBPF map

.rodata
78 bytes

ArrayMap
size = 1
[0] = <78 bytes>

Загрузка eBPF

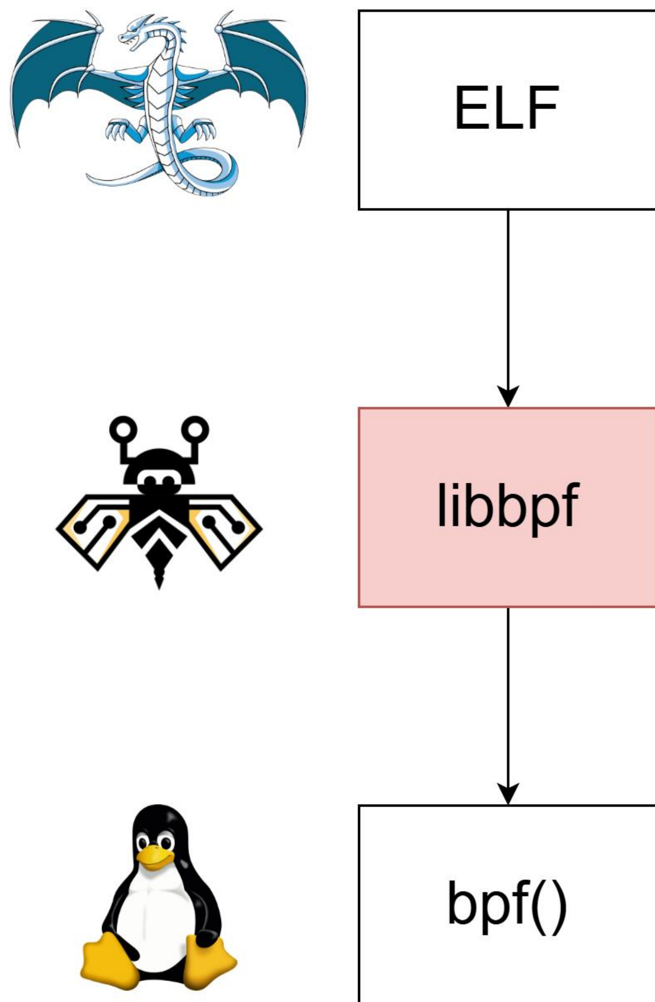

- Собирает функции в программы
- Конвертирует rodata в eBPF map

.rodata
78 bytes

ArrayMap frozen

size = 1
[0] = <78 bytes>

Загрузка eBPF

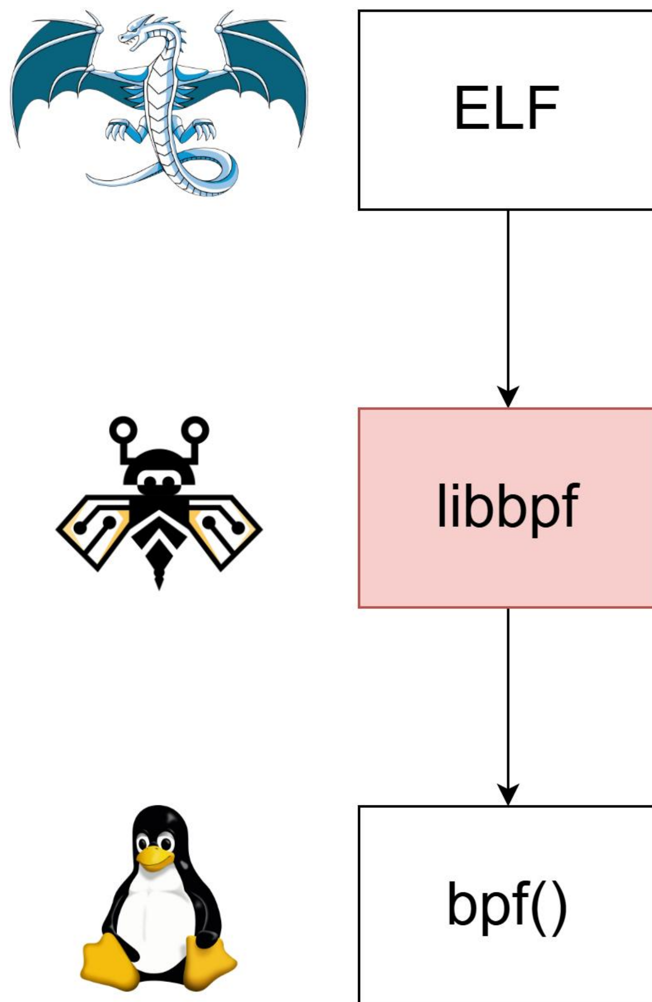

- Собирает функции в программы
- Конвертирует rodata в eBPF map

.rodata
78 bytes

ArrayMap
frozen
size = 1
[0] = <78 bytes>

r2=<.rodata+0x78>

r2 = &map[0]+0x78

Загрузка eBPF

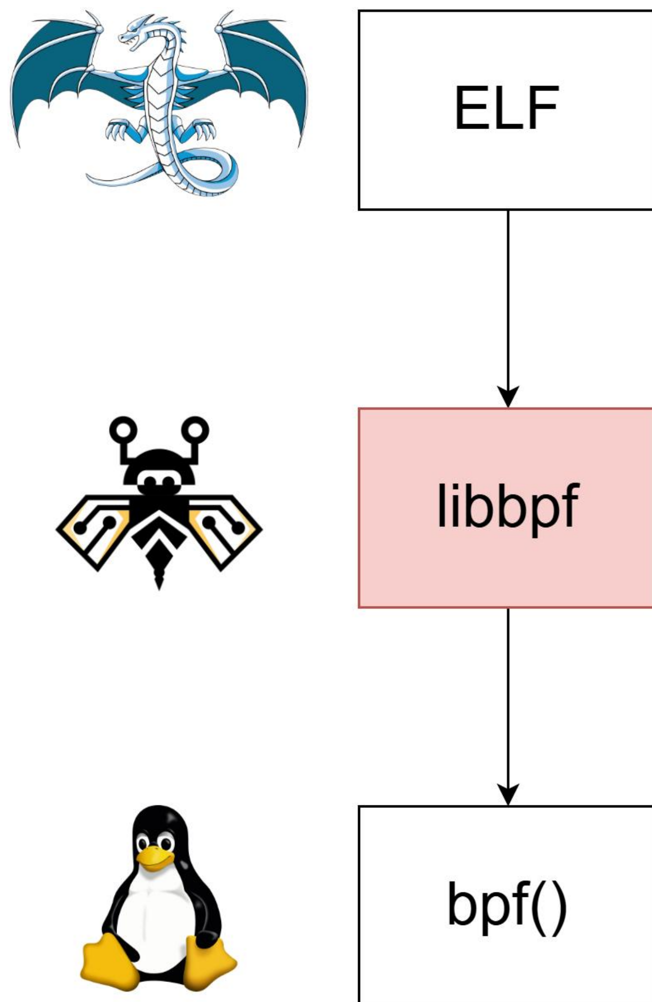

- Собирает функции в программы
- Конвертирует rodata в eBPF map

.rodata
78 bytes

ArrayMap frozen

size = 1
[0] = <78 bytes>

r2=<.rodata+0x78>

r2 = &map[0]+0x78

r2 = <const addr>

Загрузка eBPF

ELF

libbpf

bpf()

- Собирает функции в программы
- Конвертирует rodata в eBPF map
- Инициализирует ресурсы (map)

Загрузка eBPF

ELF

libbpf

bpf()

- Собирает функции в программы
- Конвертирует rodata в eBPF map
- Инициализирует ресурсы (map)
- Передает байткод ядру

Загрузка eBPF

ELF

libbpf

bpf()

- Проверяет корректность (отсутствие UB)
- Удаляет мертвый код
- Инлайн ядерных функций
- Транслирует в нативные инструкции

Верификация

```c
SEC("xdp")
int xdp_scream(struct xdp_md *ctx) {
    void *pkt = (void *)(long)ctx->data;
    void *pkt_end = (void *)(long)ctx->data_end;
    u8 val = 0;

    if (pkt_end > pkt + 0x36) {
        val = *(u8 *)(pkt + 0x16);
    }

    return val == 0xAA ? XDP_PASS : XDP_DROP;
}
```

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)
    r1 = *(r1 + 0)
    r3 = r1
    r3 += 36
    if r3 >= r2 jmp +3
    r0 = *(r1 + 16)
```

Верификация

```
xdp_foo():
r2 = *(r1 + 4)
r1 = *(r1 + 0)
r3 = r1
r3 += 36
if r3 >= r2 jmp +3
r0 = *(r1 + 16)
```

r1=cxt

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)
    r1 = *(r1 + 0)
    r3 = r1
    r3 += 36
    if r3 >= r2 jmp +3
    r0 = *(r1 + 16)
```

```
r1=cxt
r2=pkt_end
r1=pkt
```

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)
    r1 = *(r1 + 0)
    r3 = r1
    r3 += 36
    if r3 >= r2 jmp +3
    r0 = *(r1 + 16)
```

```
r1=cxt
r2=pkt_end
r1=pkt
r3=pkt
r3=pkt(off=36)
```

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)          r1=cxt
    r1 = *(r1 + 0)          r2=pkt_end
    r3 = r1                 r1=pkt
    r3 += 36                r3=pkt
    if r3 >= r2 jmp +3      r3=pkt(off=36)
    r0 = *(r1 + 16)
                            sizeof(pkt) > 36
```

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)
    r1 = *(r1 + 0)
    r3 = r1
    r3 += 36
    if r3 >= r2 jmp +3
    r0 = *(r1 + 16)
```

```
r1=cxt
r2=pkt_end
r1=pkt
r3=pkt
r3=pkt(off=36)

sizeof(pkt) > 36
```

Верификация

```
xdp_foo():
    r2 = *(r1 + 4)          r1=cxt
                            r2=pkt_end
    r1 = *(r1 + 0)          r1=pkt
    r3 = r1                 r3=pkt
    r3 += 36                r3=pkt(off=36)
    if r3 >= r2 jmp +3
                            sizeof(pkt) > 36
    r0 = *(r1 + 50)
```

Верификация

“Исполняет” код и следит за

- Типом регистров
- Диапазоном значений (min/max)
- Control Flow

Верификация

“Исполняет” код и следит за

- Типом регистров
- Диапазоном значений (min/max)
- Control Flow

× Очень хрупкая конструкция

Верификация

```
SEC("xdp")
int xdp_scream(struct xdp_md *ctx) {
    void *pkt = (void *)(long)ctx->data;
    void *pkt_end = (void *)(long)ctx->data_end;
    u8 val = 0;

    if (pkt_end > pkt + 0x36) {
        val = *(u8 *)(pkt + 0x16);
    }

    return val == 0xAA ? XDP_PASS : XDP_DROP;
}
```

Верификация

```c
SEC("xdp")
int xdp_scream(struct xdp_md *ctx) {
    void *pkt = (void *)(long)ctx->data;
    void *pkt_end = (void *)(long)ctx->data_end;
    u8 val = 0;

    int pkt_size = pkt_end - pkt;
    if (pkt_size > 0x36) {
        val = *(u8 *)(pkt + 0x16);
    }

    return val == 0xAA ? XDP_PASS : XDP_DROP;
}
```

Верификация

```
SEC("xdp")
int xdp_scream(struct xdp_md *ctx) {
    void *pkt = (void *)(long)ctx->data;
    void *pkt_end = (void *)(long)ctx->data_end;
    u8 val = 0;

    int pkt_size = pkt_end - pkt;
    if (pkt_size > 0x36) {
        val = *(u8 *)(pkt + 0x16);
    }

    return val == 0xAA ? XDP_PASS : XDP_DROP;
}
```

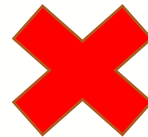

pkt_size = scalar()
pkt_size = scalar(0x37, MAX)
sizeof(pkt) = ??

Верификация

```
addr->p1 = ctx->dst_ip6[0];

addr->p2 = ctx->dst_ip6[1];

addr->p3 = ctx->dst_ip6[2];

addr->p4 = ctx->dst_ip6[3];
```

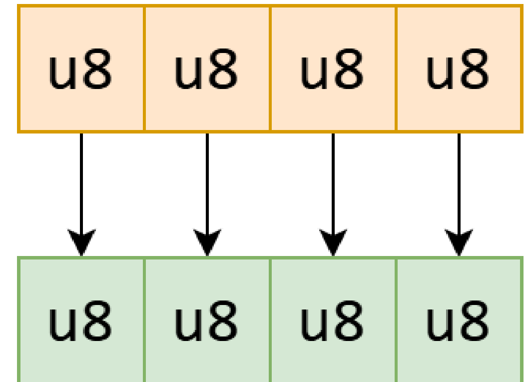

Верификация

```
addr->p1 = ctx->dst_ip6[0];

addr->p2 = ctx->dst_ip6[1];

addr->p3 = ctx->dst_ip6[2];

addr->p4 = ctx->dst_ip6[3];
```

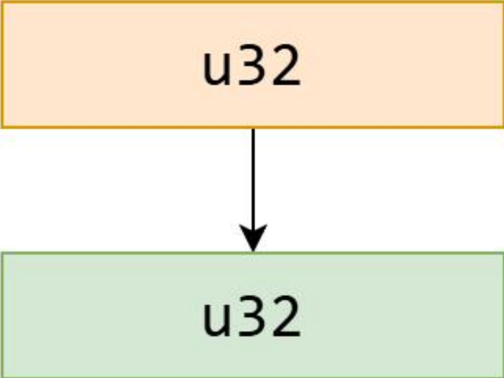

[u8 x 4] = u32

Верификация

```
addr->p1 = ctx->dst_ip6[0];

addr->p2 = ctx->dst_ip6[1];

addr->p3 = ctx->dst_ip6[2];

addr->p4 = ctx->dst_ip6[3];
```

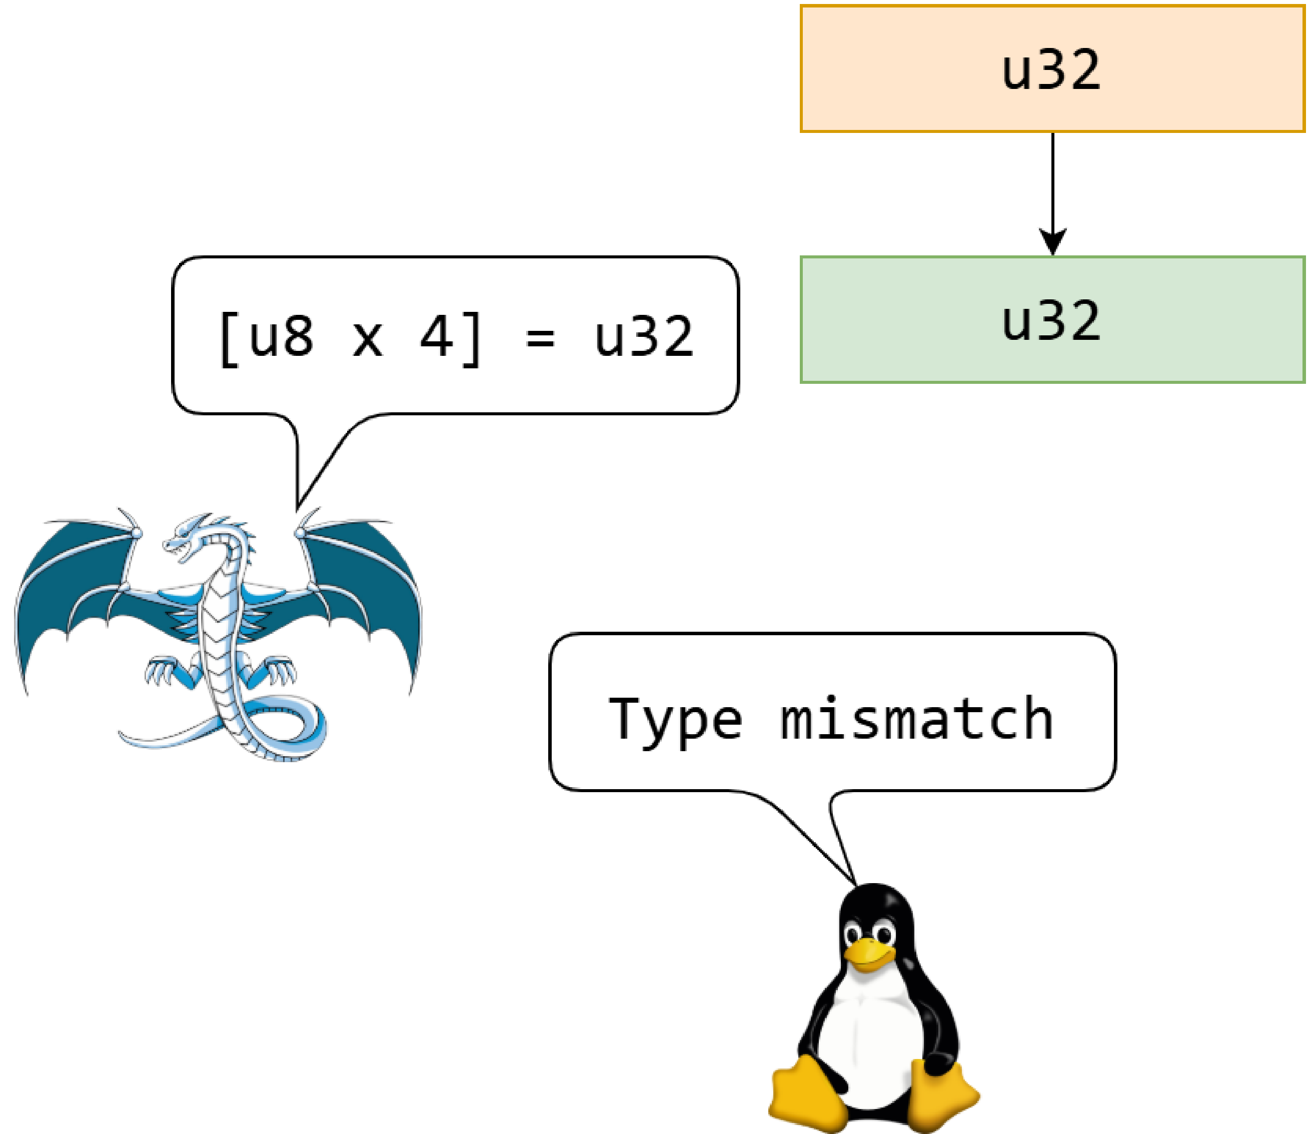

Верификация

```
addr->p1 = ctx->dst_ip6[0];
asm volatile("" ::: "memory");
addr->p2 = ctx->dst_ip6[1];
asm volatile("" ::: "memory");
addr->p3 = ctx->dst_ip6[2];
asm volatile("" ::: "memory");
addr->p4 = ctx->dst_ip6[3];
asm volatile("" ::: "memory");
```

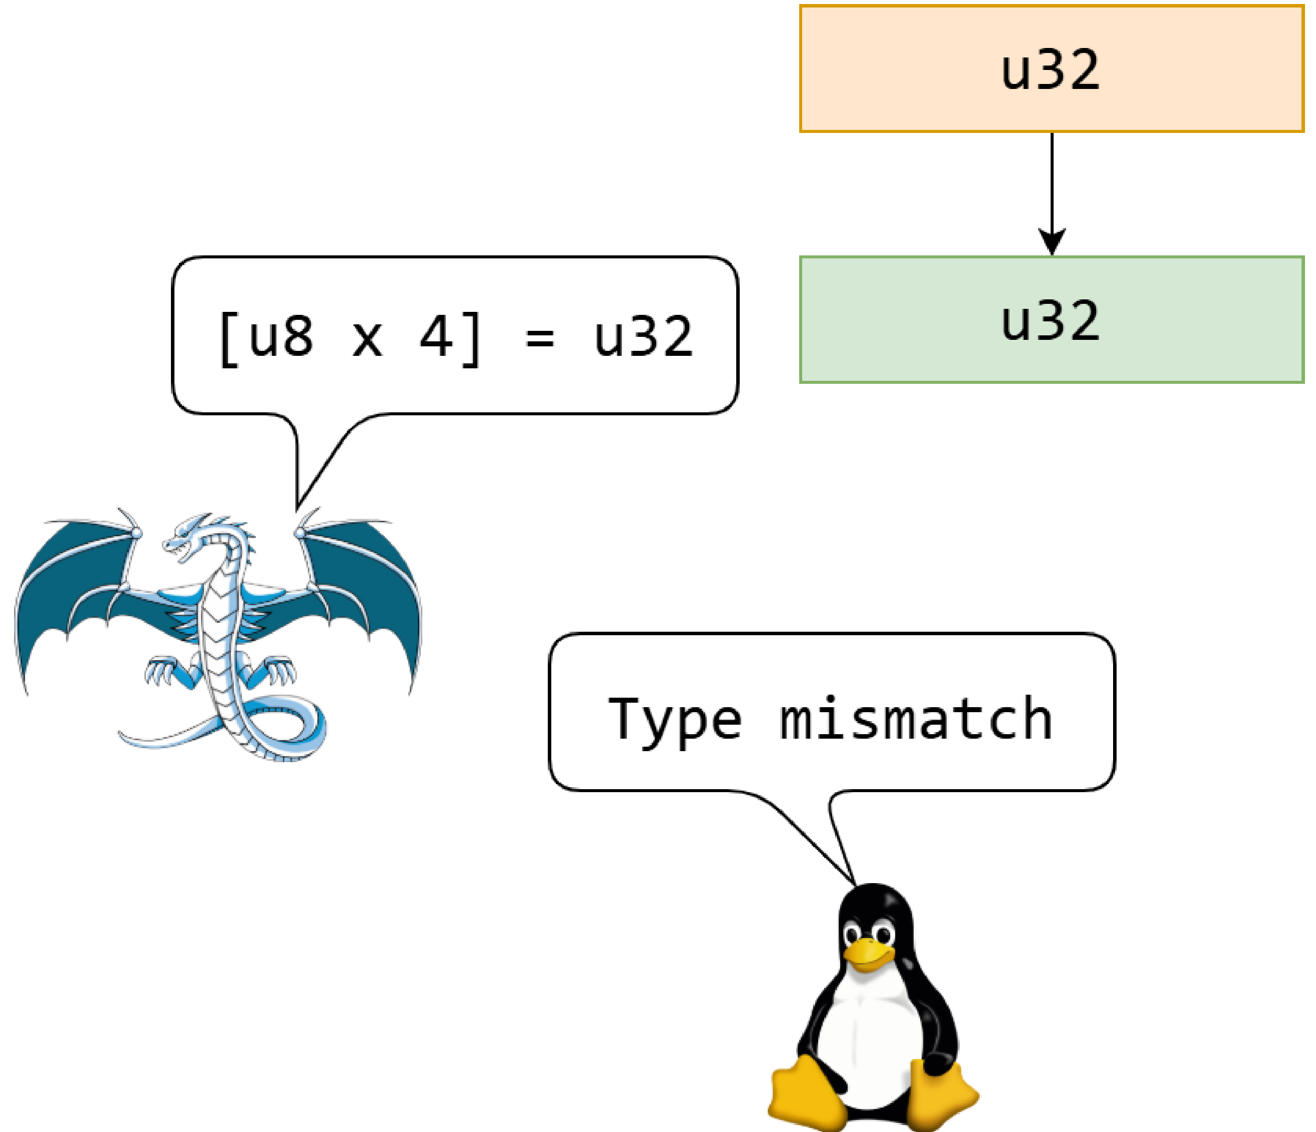

Верификация

В реальности борьба с верификатором приводит к

- Компиляторным барьерам

  Особенно внутри циклов

- Копипаст кода (через inline)
- volatile read
- volatile asm

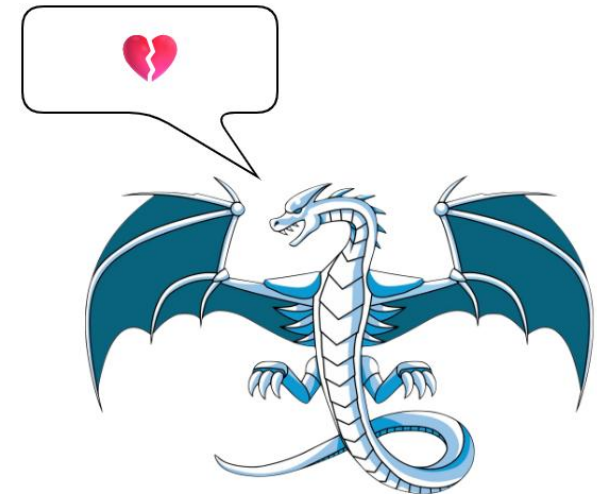

Загрузка eBPF

ELF

libbpf

bpf()

- ~~Верификация~~

  Вынуждает писать неоптимально
- Удаляет мертвый код
- Инлайн ядерных функций
- Транслирует в нативные инструкции

Dead Code Elimination: Why

> Откуда вообще берется мертвый код?

Dead Code Elimination: Why

> Откуда вообще берется мертвый код?

- `const volatile`

```
if (CONFIG(encryption_strict_ingress) && !ctx_is_decrypt(ctx)) {
    ret = DROP_UNENCRYPTED_TRAFFIC;
    goto out;
}
```

Dead Code Elimination: Why

> Откуда вообще берется мертвый код?

- `const volatile`

```
if (CONFIG(encryption_strict_ingress) && !ctx_is_decrypt(ctx)) {
    ret = DROP_UNENCRYPTED_TRAFFIC;
    goto out;
}
```

```
#define CONFIG(name)
(*({
    void *out;
    asm volatile("%0 = " __stringify(__config_##name) " ll"
            : "=r"(out));
    (typeof(__config_##name) *)out;
}))
```

Dead Code Elimination: Why

> Откуда вообще берется мертвый код?

- `const volatile`
- “Рантайм” информация

```
/*
 * Fallback to the old API if the kernel doesn't support
 * scx_bpf_select_cpu_and().
 *
 * This is required to support kernels <= 6.16.
 */
if (!bpf_ksym_exists(scx_bpf_select_cpu_and)) {
        bool is_idle = false;
```

Dead Code Elimination: How

```
CONFIG_TRUE ? 100 : 200
```

```
r1 = &CONFIG_TRUE          r1=const ptr
r1 = *(r1 + 0)             r1=scalar()
if r1 != 0 jmp +2
r2 = 200
jmp +1
r2 = 100
```

Dead Code Elimination: How

```
CONFIG_TRUE ? 100 : 200
```

`r1 = &CONFIG_TRUE`	`r1=const ptr`
`r1 = *(r1 + 0)`	`r1=scalar(true)`
`if r1 != 0 jmp +2`	
`r2 = 200`	
`jmp +1`	
`r2 = 100`	

Dead Code Elimination: How

```
CONFIG_TRUE ? 100 : 200
```

Instruction	State
`r1 = &CONFIG_TRUE`	`r1=const ptr`
`r1 = *(r1 + 0)`	`r1=scalar(true)`
`jmp +2`	
`r2 = 200`	
`jmp +1`	
`r2 = 100`	

Dead Code Elimination: How

```
CONFIG_TRUE ? 100 : 200
```

`r1 = &CONFIG_TRUE`	`r1=const ptr`
`r1 = *(r1 + 0)`	`r1=scalar(true)`
`r2 = 100`	

Dead Code Elimination: Result

- Можем выкинуть до 80% кода
  - слишком много опций
  - сложная реализация совместимости
- Упрощаем Control Flow граф

Dead Code Elimination: Result

- Можем выкинуть до 80% кода
- Упрощаем Control Flow граф

Изначально:

× Неэффективная аллокация регистров
× Неправильный расчет инлайна
× Пессимистичный Control Flow

Загрузка eBPF

ELF

libbpf

bpf()

- ~~Верификация~~

  Вынуждает писать неоптимально

- ~~Удаляет мертвый код~~

  Было скомпилировано пессимистично

- Инлайн ядерных функций
- Транслирует в нативные инструкции

Inline: Что подставляется

- Интринсики
  - Адрес хештаблицы
- “Простые” функции
  map_lookup(), get_processor_id(), bpf_loop(), …
- Трансформации для удобства JIT
  Деление как тернарный оператор

Inline: Как реализовано

```
insn_buf[0] = BPF_JMP_IMM(BPF_JNE, BPF_REG_3, 0, 7);

/* Transform size (bytes) into number of entries (cnt = size / 24). */
insn_buf[1] = BPF_MOV32_IMM(BPF_REG_0, 0xaaaaaaab);
insn_buf[2] = BPF_ALU64_REG(BPF_MUL, BPF_REG_2, BPF_REG_0);
insn_buf[3] = BPF_ALU64_IMM(BPF_RSH, BPF_REG_2, 36);

/* call perf_snapshot_branch_stack implementation */
insn_buf[4] = BPF_EMIT_CALL(static_call_query(perf_snapshot_branch_stack));
/* if (entry_cnt == 0) return -ENOENT */
insn_buf[5] = BPF_JMP_IMM(BPF_JEQ, BPF_REG_0, 0, 4);
/* return entry_cnt * sizeof(struct perf_branch_entry) */
insn_buf[6] = BPF_ALU32_IMM(BPF_MUL, BPF_REG_0, br_entry_size);
insn_buf[7] = BPF_JMP_A(3);
/* return -EINVAL; */
insn_buf[8] = BPF_MOV64_IMM(BPF_REG_0, -EINVAL);
insn_buf[9] = BPF_JMP_A(1);
/* return -ENOENT; */
insn_buf[10] = BPF_MOV64_IMM(BPF_REG_0, -ENOENT);
```

6 базовых блоков

3 различных выхода

Inline: Проблемы

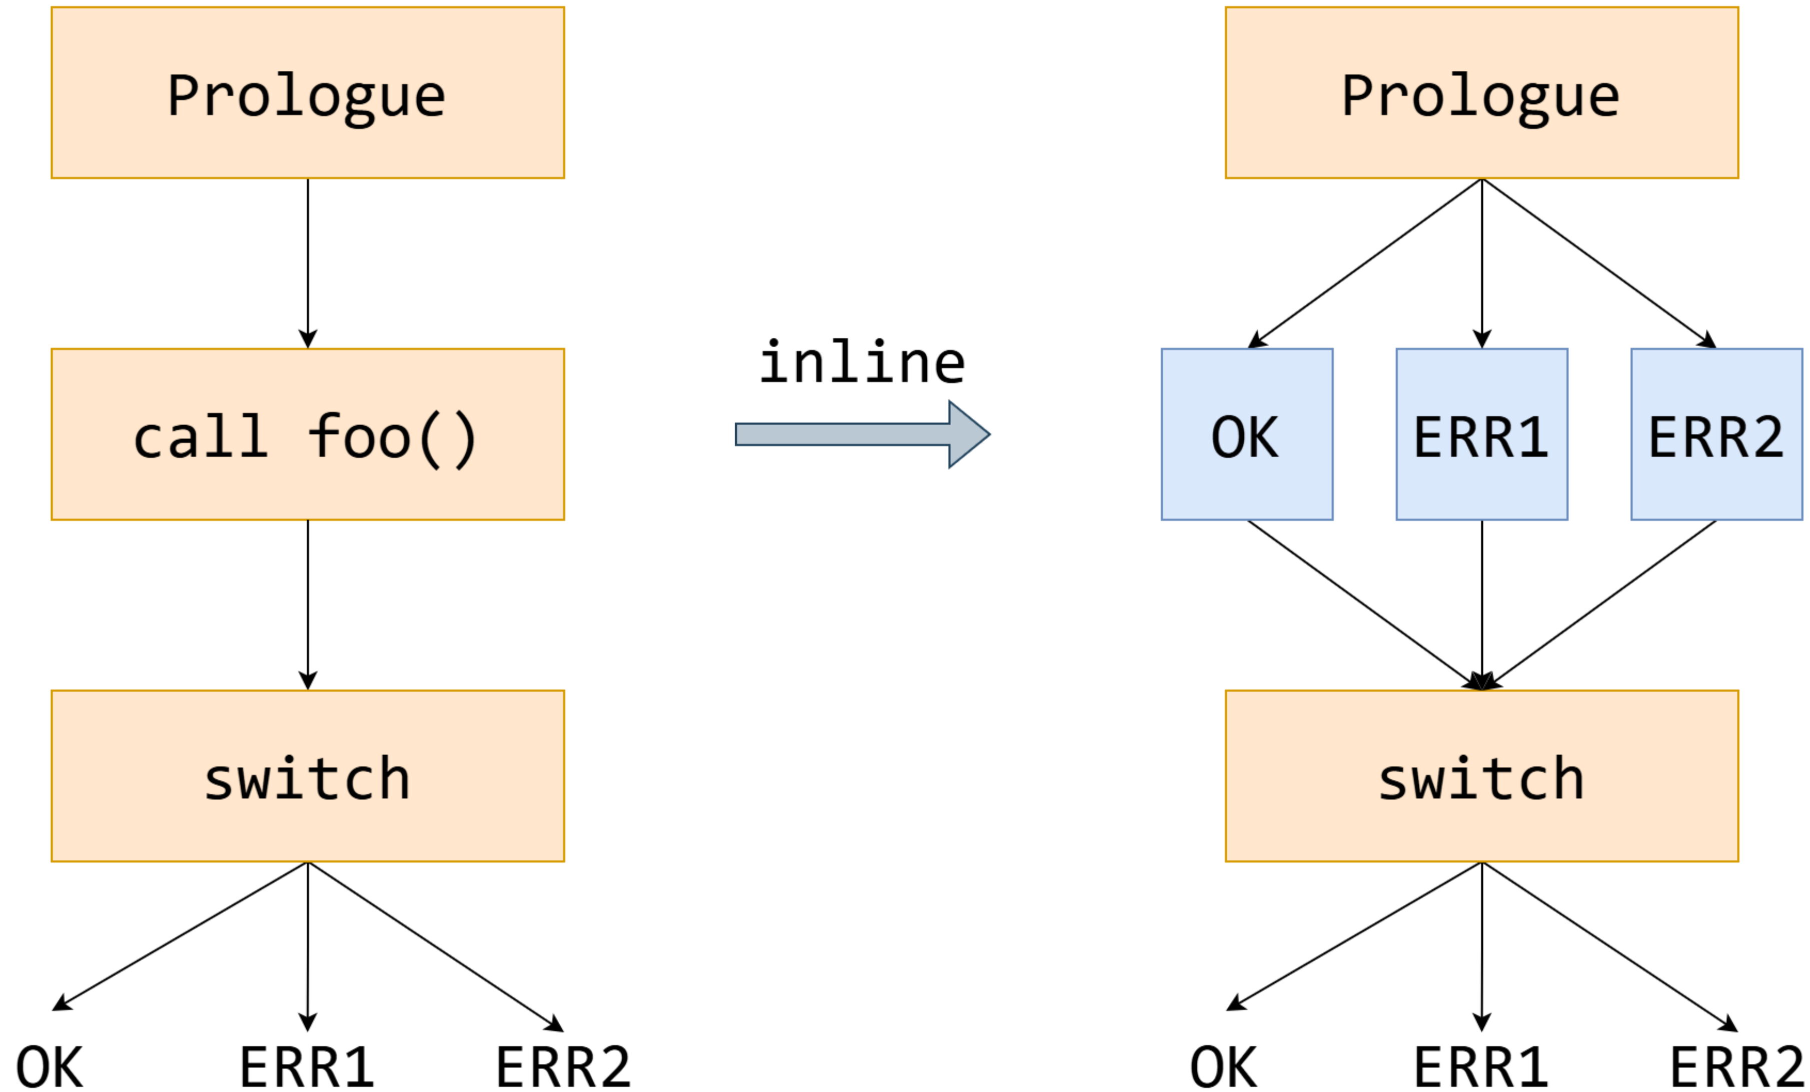

Inline: Проблемы

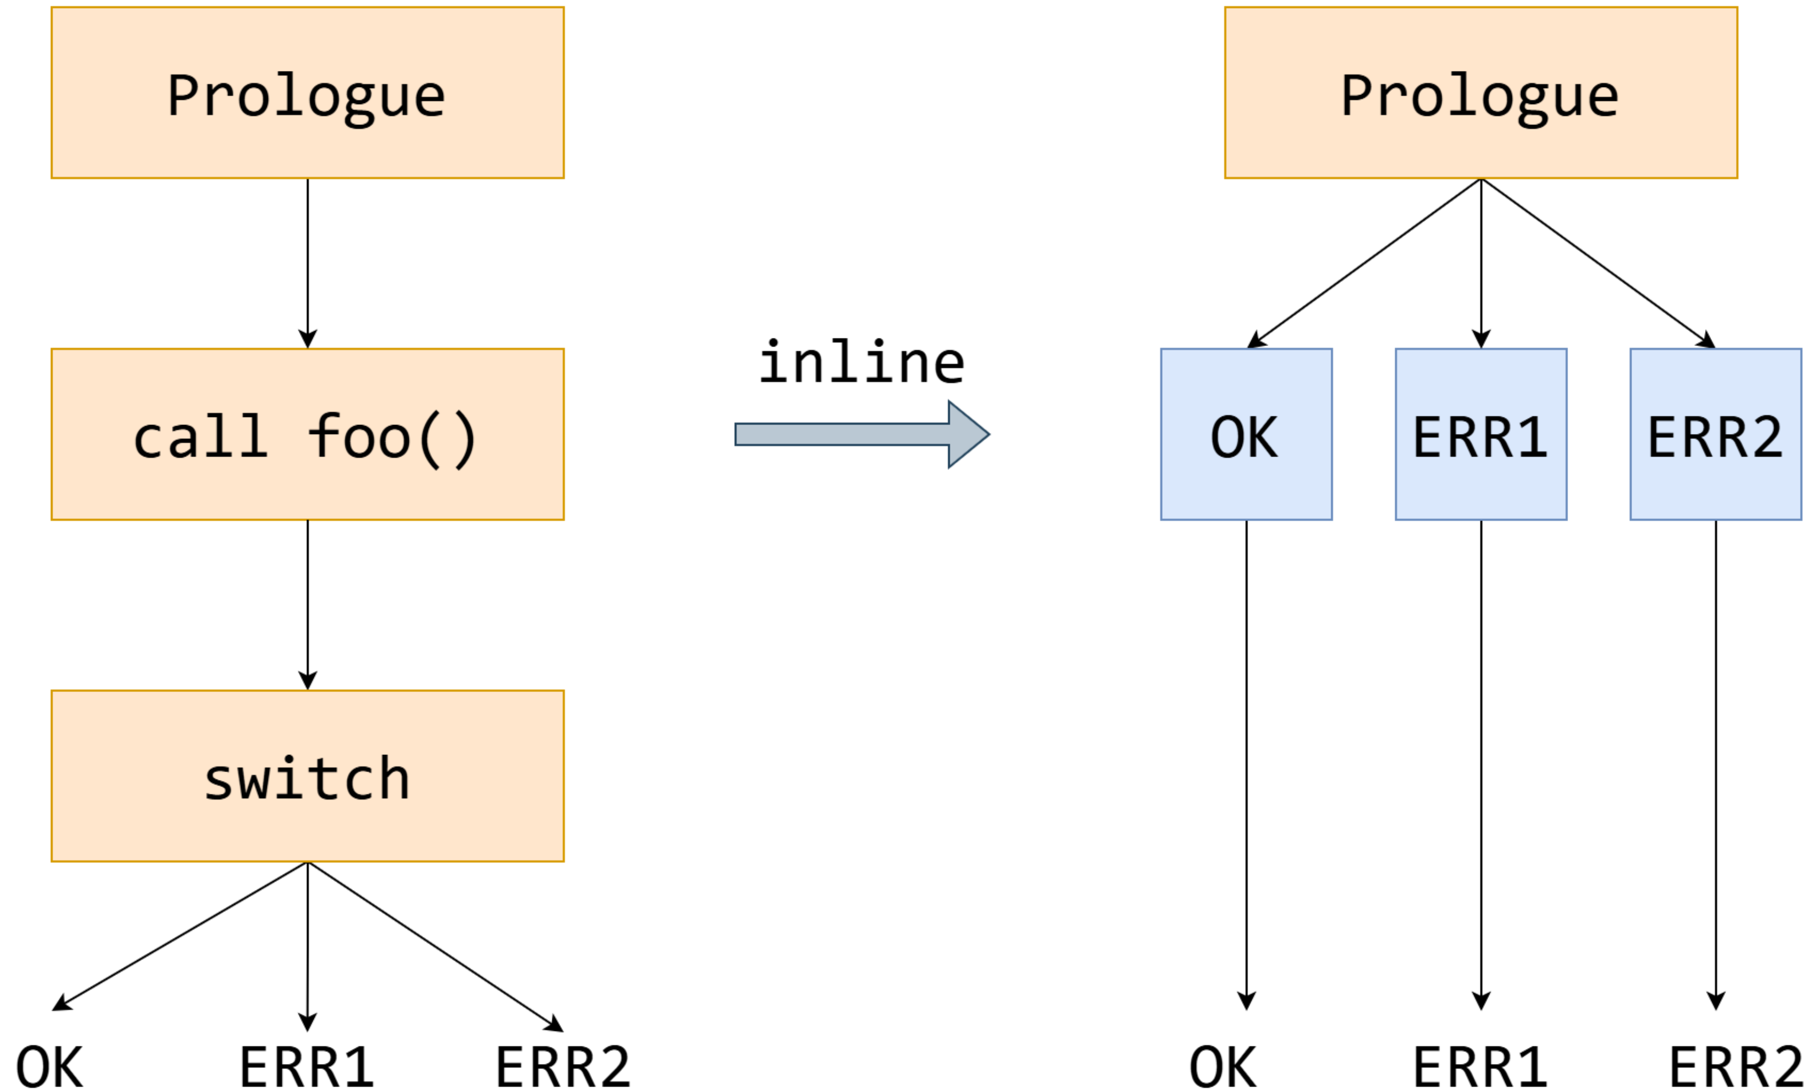

Inline

✓Экономим на call / ret

×Не переаллоцируем регистры
×Не упрощаем Control Flow
×Исходный код был собран пессимистично

Загрузка eBPF

ELF

libbpf

bpf()

- ~~Верификация~~

  Вынуждает писать неоптимально
- ~~Удаляет мертвый код~~

  Было скомпилировано пессимистично
- ~~Подставляет ядерные функции~~

  Экономия на спичках
- Транслирует в нативные инструкции

Трансляция

- Регистры отображаются 1:1
- Инструкции транслируются по одной

```
r6 += r3
```

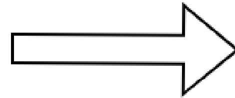

```
add %rdx, %rbx
```

```
r2 = *(r1 + 8)
```

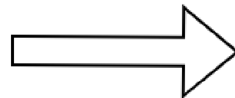

```
mov 0x8(rdi), %rdx
```

```
if r3 >= r2
goto pc+5
```

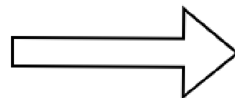

```
cmp %rdi, %rsi
jae <+5>
```

Трансляция

! Инструкции имеют разную семантику

```
r9 /= 100
```

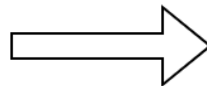

```
div 100, %r15
```

Трансляция

! Инструкции имеют разную семантику

В x64 зафиксирован `source = rax:rdx`

```
r9 /= 100
```

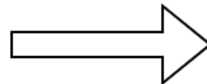

```
xor %rdx, %rdx
mov %r15, %rax
div 100
mov %rax, %r15
```

Трансляция

! Инструкции имеют разную семантику

В x64 делить можно только на регистр

```
r9 /= 100
```

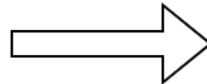

```
mov 100, %r11
xor %rdx, %rdx
mov %r15, %rax
div %r11
mov %rax, %r15
```

Трансляция

! Инструкции имеют разную семантику

Нельзя инвалидировать eBPF регистры

```
r9 /= 100
```

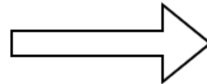

```
push %rax
push %rdx
mov 100, %r11
xor %rdx, %rdx
mov %r15, %rax
div %r11
mov %rax, %r15
pop %rdx
pop %rax
```

Трансляция

- ✓ Зачастую эффективна
- ✓ Прямолинейная для большинства инструкций

- × Проблемы с разной семантикой
- × Ограничены выразительностью байткода

Конвейер загрузки

ELF

libbpf

bpf()

- ~~Верификация~~
  Вынуждает писать неоптимально
- ~~Удаляет мертвый код~~
  Было скомпилировано пессимистично
- ~~Подставляет ядерные функции~~
  Экономия на спичках
- ~~Транслирует в нативные инструкции~~
  По одной инструкции неэффективно

Хотим лучше

- Не меняя интерфейс
  - Иначе модули + Rust-for-Linux
- Сохраняя гарантии корректности
  - Не трогаем верификатор
- Максимально простое решение
  - Не изобретаем компилятор в ядре

Хотим лучше

- >Не меняя интерфейс
- >Сохраняя гарантии корректности
- >Максимально простое решение

⇒ Существующий компилятор после верификации

UJIT

- Демон в userspace + интеграция в ядре
- Мы доверяем компилятору (root)

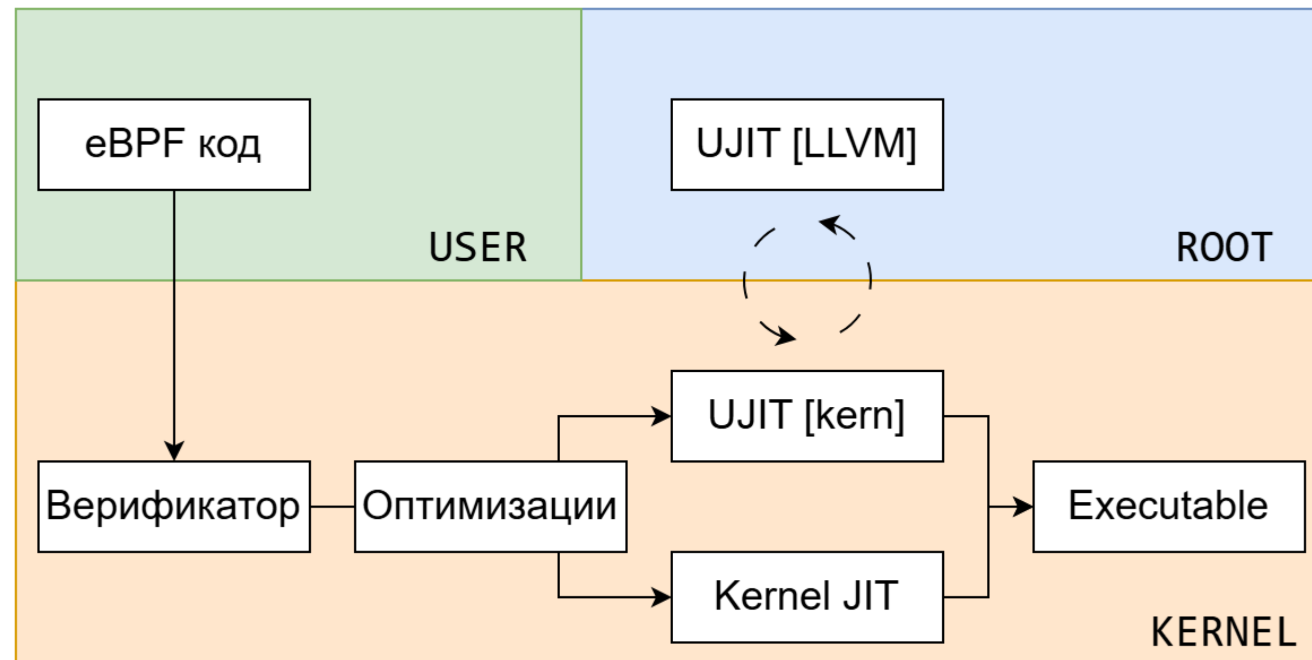

UJIT: Детали

- Время компиляции от 30ms до 500ms
  - Ориентировано на долгоживущие программы
- Программа и подпрограммы компилируются вместе
  - Позволяет переделать inline
  - Знаем больше чем верификатор
- `march=native*`
  - jump-таблицы, mov
  - popcnt

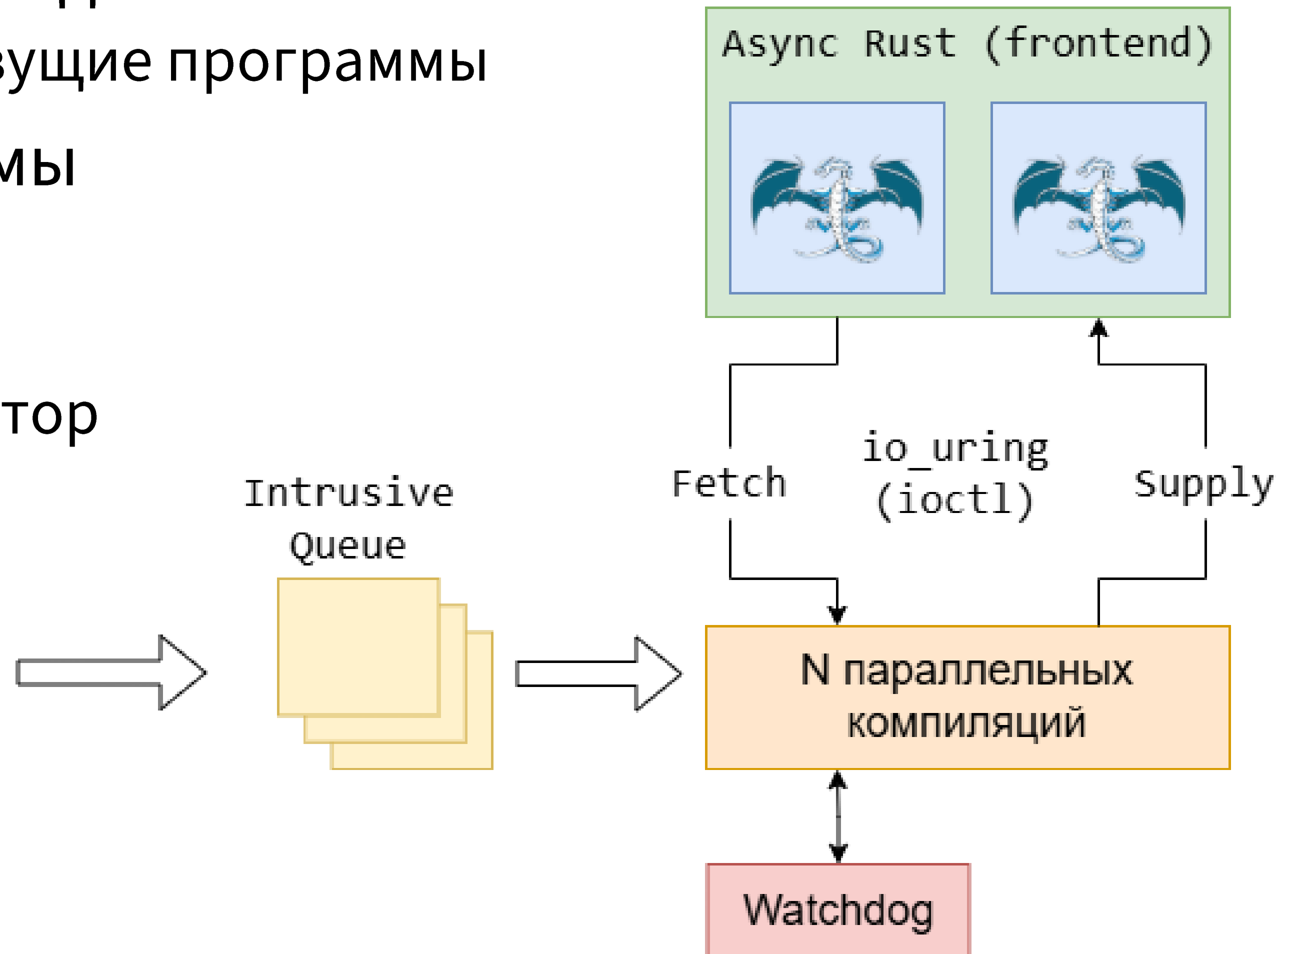

UJIT: Трансляция

- Разбиваем на базовые блоки
- Регистры и стек – локальные переменные
  - ABI не использует стек
- Транслируем по одной инструкции
  - O2/O3 соптимизирует

```
u64 ebpf_function(u64 arg1) {
    u64 r0, r1 = arg1, r2, /*... ,*/ r10;
    u8 stack[STACK_SIZE];

    /* Generate code for each instruction */
    {
      r1 = 0xFFFFDEAD;
    }
    {
      u64 (*kfuncptr)(u64) = 0xDEADC0DE;
      r0 = kfuncptr(r1);
    }

    return r0;
}
```

UJIT: Трансляция

- Разбиваем на базовые блоки
- Регистры и стек – локальные переменные
  - ABI не использует стек
- Транслируем по одной инструкции
  - O2/O3 соптимизирует

! Надо знать сигнатуру функций
  - Достаем в ядре из верификатора и инлайнера

! Сложно обнаруживать баги
  - У eBPF хорошее покрытие тестами

```
u64 ebpf_function(u64 arg1) {
    u64 r0, r1 = arg1, r2, /*... ,*/ r10;
    u8 stack[STACK_SIZE];

    /* Generate code for each instruction */
    {
      r1 = 0xFFFFDEAD;
    }
    {
      u64 (*kfuncptr)(u64) = 0xDEADC0DE;
      r0 = kfuncptr(r1);
    }

    return r0;
}
```

UJIT: Нюансы

- Бинарная совместимость с in-kernel JIT
  - Невыгодно: счетчик tail call вызовов передается через стек
  - Опасно: отслеживать версии ядра с точностью до коммита

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT
  - Нельзя смешивать программы от разных JIT

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT

  Нельзя смешивать программы от разных JIT
- Исключения (unwind)
  - В ядре регистры сохраняются при входе в каждую функцию
  - У UJIT больше набор регистров => неприменимо

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT
  - Нельзя смешивать программы от разных JIT
- Не поддерживаем исключения (пока что)
  - Нельзя вызывать bpf_throw

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT

  Нельзя смешивать программы от разных JIT
- Не поддерживаем исключения (пока что)

  Нельзя вызывать bpf_throw
- Байткод не содержит всей информации
  - Например, теряем атрибуты likely или null checks

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT
  - Нельзя смешивать программы от разных JIT
- Не поддерживаем исключения (пока что)
  - Нельзя вызывать bpf_throw
- Байткод не содержит всей информации
  - Редко используются + static branch “predictor”

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT
  Нельзя смешивать программы от разных JIT
- Не поддерживаем исключения (пока что)
  Нельзя вызывать bpf_throw
- Байткод не содержит всей информации
  Редко используются + static branch “predictor”
- Конфликт с будущей моделью памяти eBPF
  - LLVM умнее процессора в aliasing
  - Распространяется только на странный eBPF ассемблер

UJIT: Нюансы

- Отсутствует бинарная совместимость с in-kernel JIT
  - Нельзя смешивать программы от разных JIT
- Не поддерживаем исключения (пока что)
  - Нельзя вызывать bpf_throw
- Байткод не содержит всей информации
  - Редко используются + static branch “predictor”
- Конфликт с будущей моделью памяти eBPF
  - Под ответственность пользователя (пока что)

UJIT: Производительность

- 40% меньше инструкций
  - Выигрыш по размеру меньше
- ~1.5x ускорение eBPF
- XX% уменьшение latency в Cilium

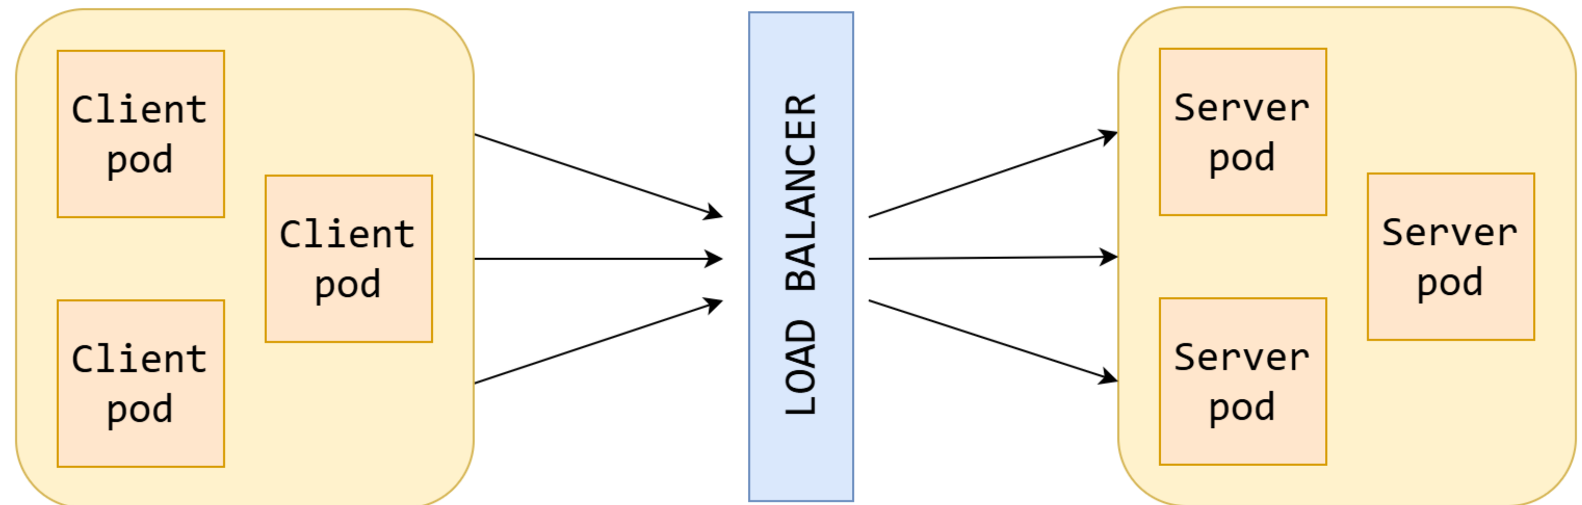

UJIT: Производительность

28% of ksys_write

UJIT: Производительность

- 40% меньше инструкций
  - Выигрыш по размеру меньше
- ~1.5x ускорение eBPF
- 5% уменьшение latency в Cilium

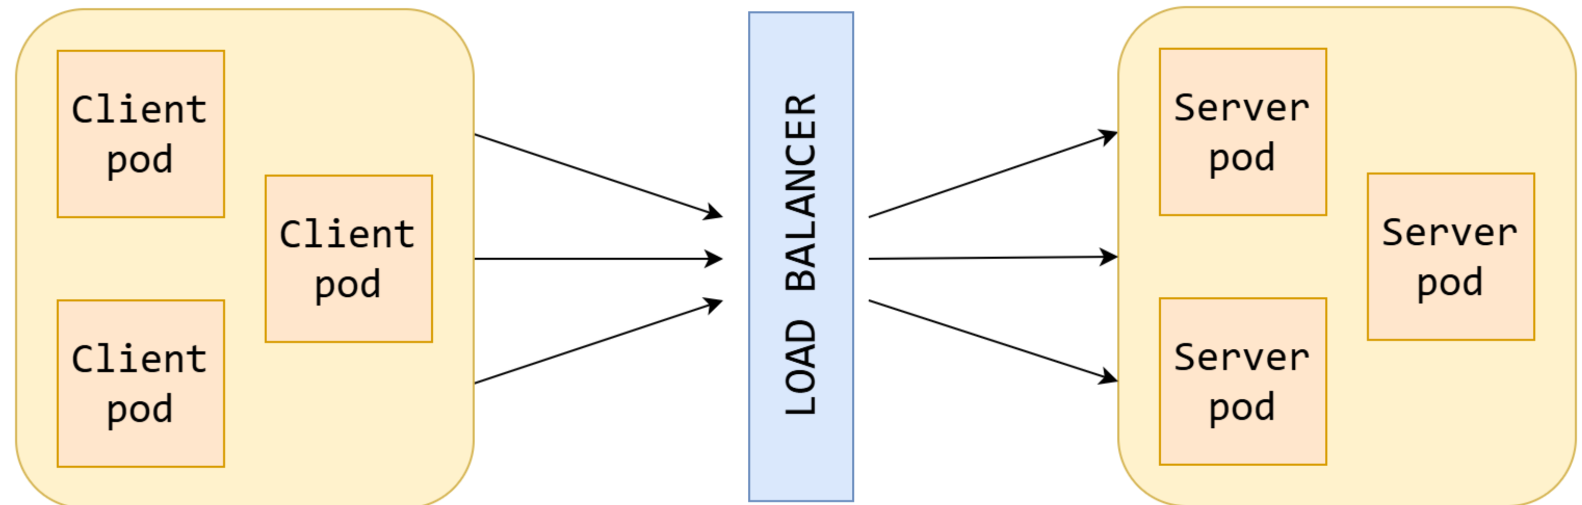

UJIT: Производительность

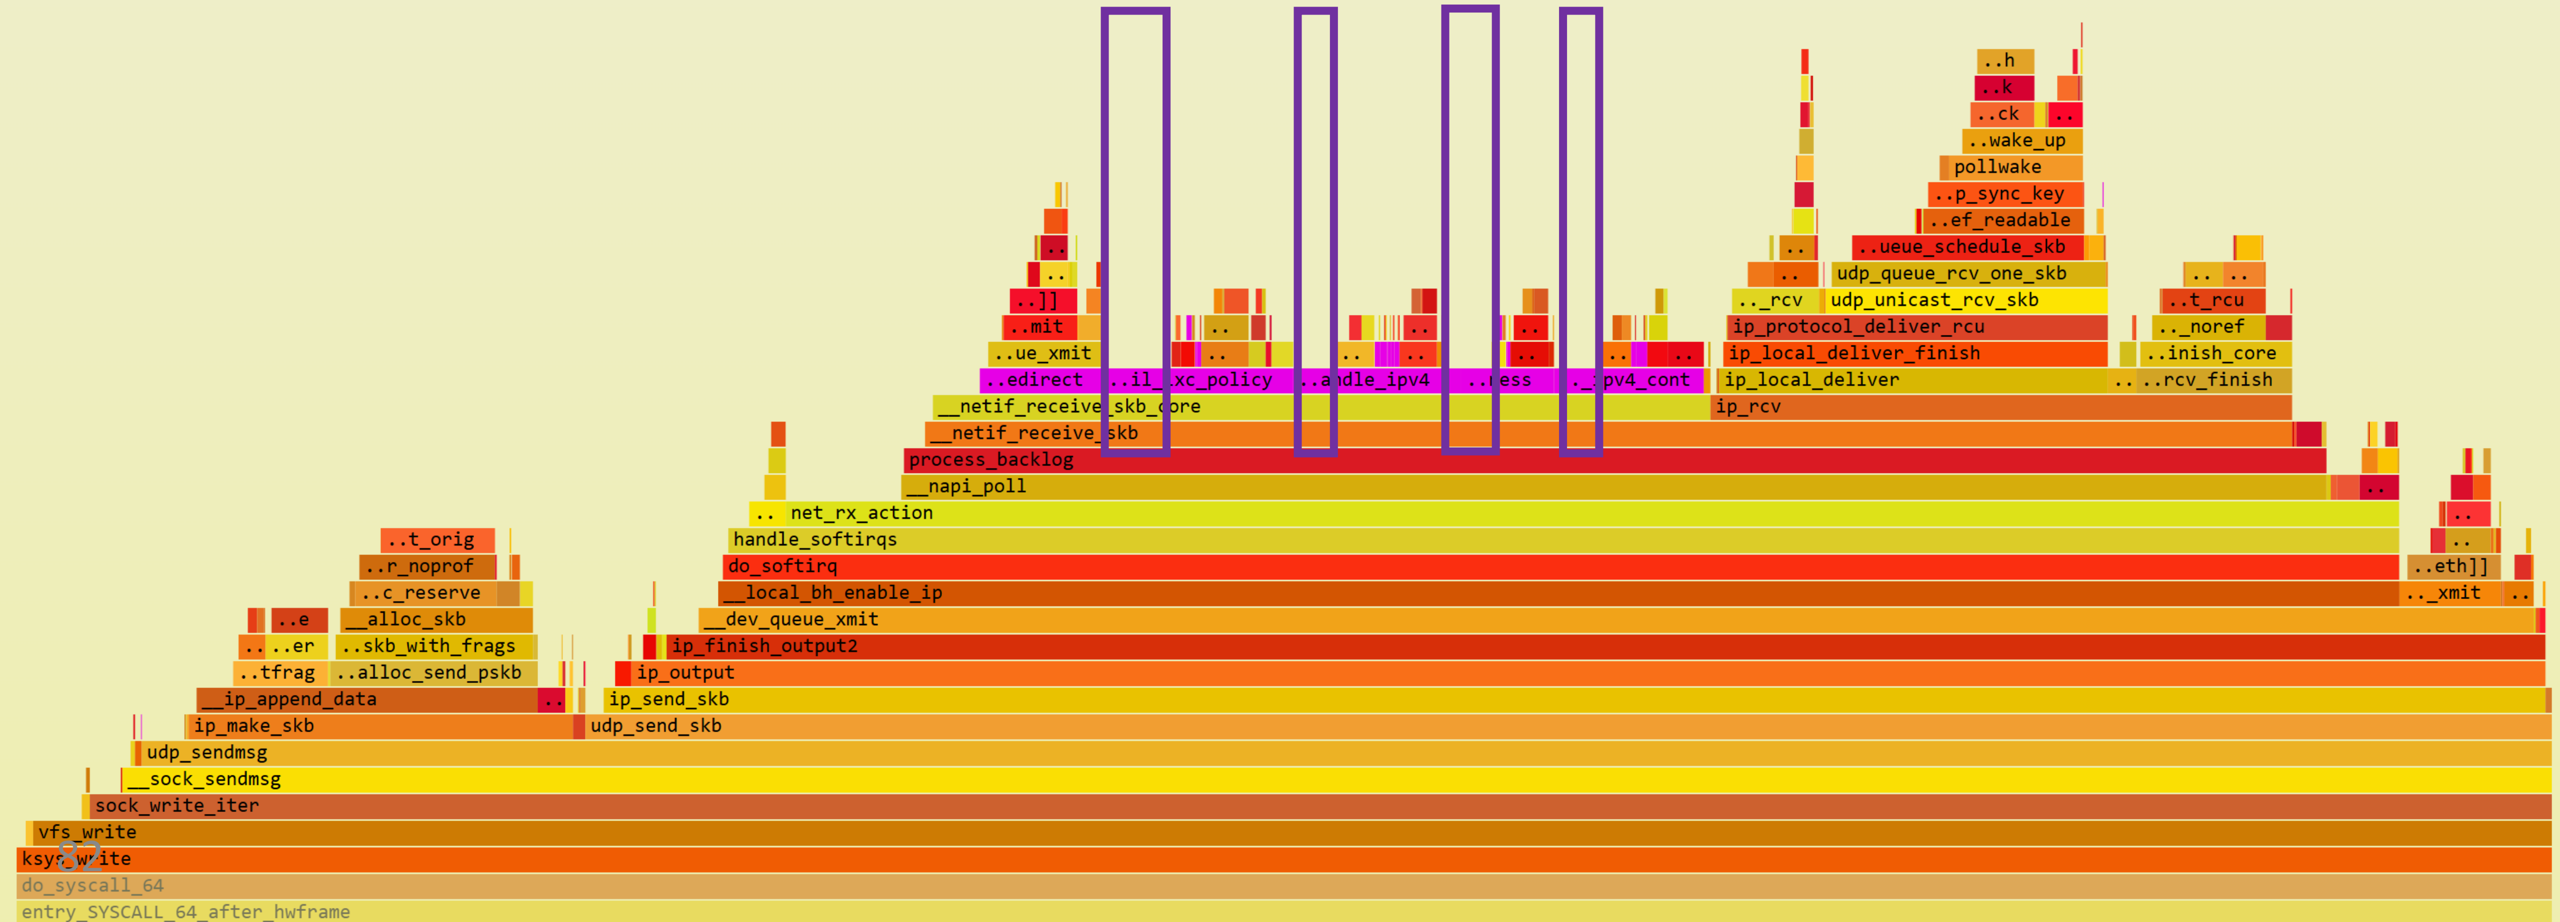

UJIT: Производительность

- 40% меньше инструкций

  Выигрыш по размеру меньше
- ~1.5x ускорение eBPF
- 5% уменьшение latency в Cilium

  Сам байткод занимает мало времени

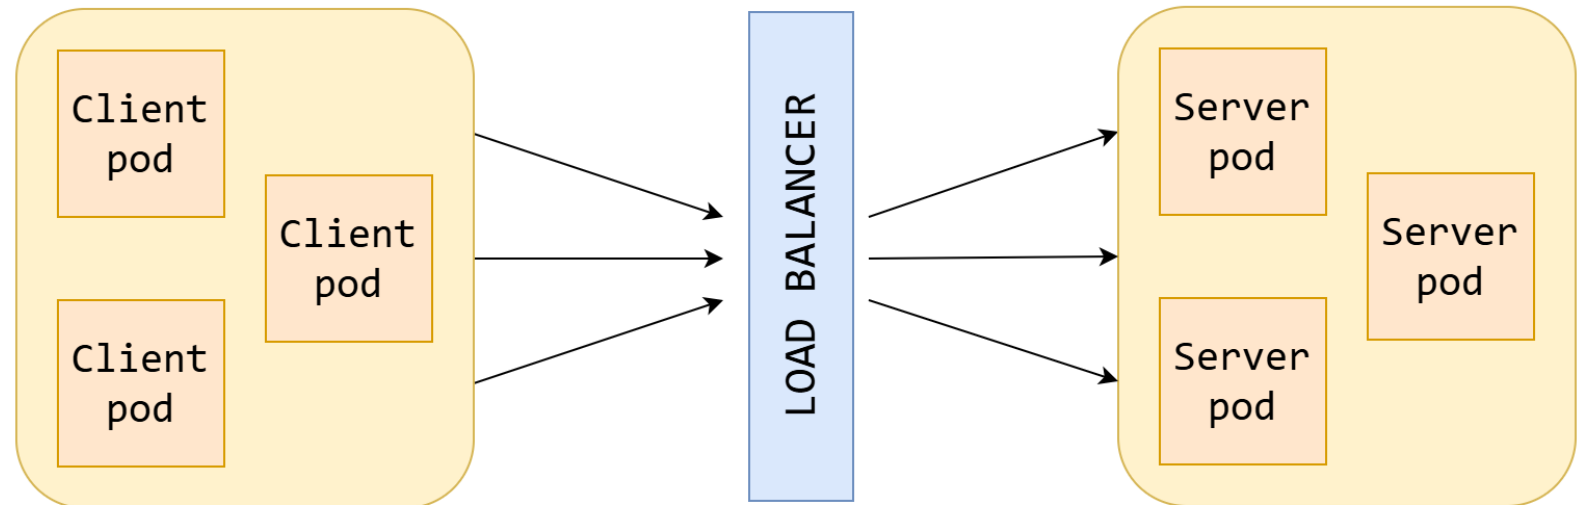

UJIT: Будущее

- Программы раздроблены из-за ограничений сложности
  - Оптимизация с помощью “LTO”

UJIT: Будущее

- Программы раздроблены из-за ограничений сложности
  - Оптимизация с помощью “LTO”
- Проверки корректности в ядерных функциях
  - Сделать inline проверок

UJIT: Будущее

- Программы раздроблены из-за ограничений сложности
  - Оптимизация с помощью “LTO”
- Проверки корректности в ядерных функциях
  - Сделать inline проверок
- LLVM не знает типов
  - Экспорт типов из верификатора

UJIT: Будущее

- Интеграция в OpenEuler Linux
  - В экспериментальную ветку
- Обратная связь
  - Нужны первые экспериментаторы!
- No upstream…

No upstream

- Конфликт с моделью памяти
- Хотят писать компилятор в ядре
  - Аллокатор регистров через 2 года
- “Доверяете userspace – пишите модули на Rust”

No upstream

- Конфликт с моделью памяти
- Хотят писать компилятор в ядре

  Аллокатор регистров через 2 года
- “Доверяете userspace – пишите модули на Rust”

- RFC будет отправлена в любом случае

Заключение

- Текущий дизайн eBPF приводит к низкой производительности
- Но часто этого достаточно
- Разработчик не может на это повлиять
  - Либо переписать на модули
- В ядре нет оптимизаций
- Легкими усилиями можно ускорить
  - Но развитие идеи потребует более инвазивных изменений