

Perforator

Yandex-wide profiling

Сергей Скворцов, Яндекс.Поиск

Perforator

Примерный план

- Обсудим известные проблемы профилирования
 - Вспомним, как работает perf
 - Изучим подходы к раскрутке стека
- Посмотрим, как построить cluster-wide профилировщик
 - Локальный профилировщик
 - Распределенный бэкенд
- Придумаем, как использовать полученную конструкцию

Perforator

Предметная область

- Linux
- x86-64, AArch64
- Нативные языки: C++, C, Go, Rust

Как профилировать?

Профилировать на масштабах одной программы мы умеем

Как профилировать?

Профилировать на масштабах одной программы мы умеем

- GDB: <https://poormansprofiler.org>

Как профилировать?

Профилировать на масштабах одной программы мы умеем

- GDB: <https://poormansprofiler.org>
- Linux perf

Как профилировать?

Профилировать на масштабах одной программы мы умеем

- GDB: <https://poormansprofiler.org>
- Linux perf
- Intel VTune

Как профилировать?

Профилировать на масштабах одной программы мы умеем

- GDB: <https://poormansprofiler.org>
- Linux perf
- Intel VTune
- Интегрированные профилировщики

Как профилировать?

Профилировать на масштабах одной программы мы умеем

- GDB: <https://poormansprofiler.org>
- Linux perf
- Intel VTune
- Интегрированные профилировщики
- ...

Как профилировать весь Яндекс?

Как профилировать весь Яндекс?

Нам нужен профилировщик для всего кластера

- Где сервисы тратят железо?
- Как оценивать результат оптимизаций общих компонент?
- Как ведет себя конкретный сервер?
- Как устроен конкретный сервис?
- Что общего в профиле нагрузки у разных сервисов?

Как профилировать весь Яндекс?

Множество гетерогенных сервисов

- Разные языки
- Разные версии рантайма и компиляторов
- Разные режимы сборки

Виды профилировщиков

Выбираем профилировщик

- Инструментирующие
- Семплирующие

Linux perf

- Стандартный профилировщик под Linux
- Много режимов работы, нам интересен семплирующий `perf record`
- Поддерживает много аппаратных и программных счетчиков
- Работает через Performance Monitoring Unit (PMU)

Performance Monitoring Unit (PMU)

Технология для анализа производительности CPU

- CPU раз в N событий вызывает особое прерывание
- Ядро Linux его обрабатывает и анализирует состояние процесса
- Нельзя обработать в userspace
- Разные типы событий: такты, инструкции, промахи мимо кеша и сотни специфичных для архитектуры

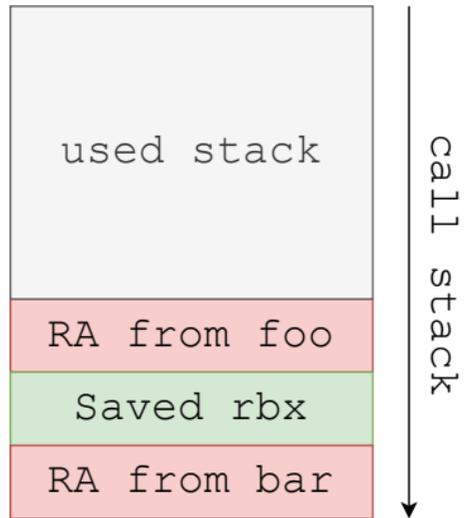
```
perf record -e cycles -c 1000000 -p 12345
```



Раскрытие стека: frame pointers

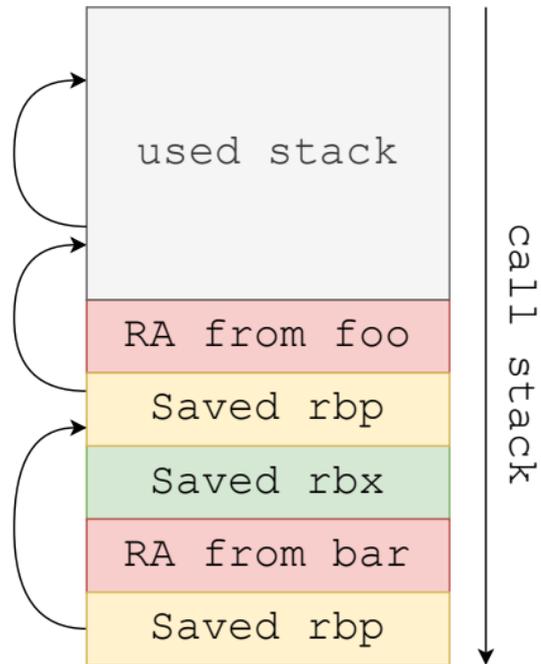
foo:

```
pushq    %rbx
movl     %edx, %ebx
callq    bar
movl     %eax, %edi
movl     %ebx, %esi
callq    bar
popq     %rbx
retq
```



Раскрытие стека: frame pointers

```
foo:
    pushq    %rbp        ; prologue
    movq    %rsp, %rbp  ; prologue
    pushq   %rbx
    movl    %edx, %ebx
    callq   bar
    movl    %eax, %edi
    movl    %ebx, %esi
    callq   bar
    popq   %rbx
    popq   %rbp        ; epilogue
    retq
```



Раскрытие стека: frame pointers

- `perf` прямо в ядре Linux собирает стек вызовов
- Код раскрытия стека очень простой, легко верифицировать

Что не так с frame pointers?

Почему бы не включить везде?

Что не так с frame pointers?

Почему бы не включить везде?

- Теряем производительность: типично 1-2%

Что не так с frame pointers?

Почему бы не включить везде?

- Теряем производительность: типично 1-2%
- Просадка сильно зависит от нагрузки: **в Clickhouse до 40%**

Что не так с frame pointers?

Почему бы не включить везде?

- Теряем производительность: типично 1-2%
- Просадка сильно зависит от нагрузки: **в Clickhouse до 40%**
- Нужно пересобирать весь мир: **долго сходится**

Что не так с frame pointers?

Почему бы не включить везде?

- Теряем производительность: типично 1-2%
- Просадка сильно зависит от нагрузки: **в Clickhouse до 40%**
- Нужно пересобирать весь мир: **долго сходится**
- Есть библиотеки и приложения, которые **не удастся пересобрать**

Что не так с frame pointers?

Почему бы не включить везде?

- Теряем производительность: типично 1-2%
- Просадка сильно зависит от нагрузки: **в Clickhouse до 40%**
- Нужно пересобирать весь мир: **долго сходится**
- Есть библиотеки и приложения, которые **не удастся пересобрать**
- Есть рукописный ассемблер: нужно **править много кода**

Раскрытие стека: DWARF

DWARF – формат отладочной информации

Для каждой инструкции в исполняемом файле закодировано, как раскрыть стек из неё

- Нужно вычислить состояние регистров на момент вызова функции
- Из `rsp` тривиально получается адрес возврата
- Повторяем для следующей функции

Раскрытие стека: DWARF

Правила для вычисления состояния регистров в начале функции

```
1  foo:
2  push  %rbp
3  push  %r14
4  push  %rbx
5  sub   $0x400,%rsp
6  ...
7  add   $0x400,%rsp
8  pop   %rbx
9  pop   %r14
10 pop   %rbp
11 ret
```

1	CFA	RA
2	rsp+8	CFA-8
3	rsp+16	CFA-8
4	rsp+24	CFA-8
5	rsp+32	CFA-8
6	rsp+1056	CFA-8
7	...	
8	rsp+32	CFA-8
9	rsp+24	CFA-8
10	rsp+16	CFA-8
11	rsp+8	CFA-8

Раскрытие стека: DWARF

Правила для вычисления состояния регистров в начале функции

```
1  foo:
2  push  %rbp
3  mov   %rsp, %rbp
4  push  %r14
5  push  %rbx
6  sub   $0x400,%rsp
7  ...
8  add   $0x400,%rsp
9  pop   %rbx
10 pop   %r14
11 pop   %rbp
12 ret
```

1	CFA	RA
2	rsp+8	CFA-8
3	rbp+16	CFA-8
4	rbp+16	CFA-8
5	rbp+16	CFA-8
6	rbp+16	CFA-8
7	rbp+16	CFA-8
8	...	
9	rbp+16	CFA-8
10	rbp+16	CFA-8
11	rbp+16	CFA-8
12	rsp+8	CFA-8

```
CFA = *(rsp + 8 + r9 << 3) + 8
```

DWARF не раскрутить в ядре Linux

Ответ на попытку реализовать раскрутку через DWARF:

DWARF не раскрутить в ядре Linux

Ответ на попытку реализовать раскрутку через DWARF:

I never *ever* want to see this code ever again. (...) An unwinder that is several hundred lines long is simply not even *remotely* interesting to me. (...) In the absence of that, just follow the damn chain on the stack *without* the "smarts" of an inevitably buggy piece of crap.

– Linus Torvalds

Что не так с DWARF?

Приходится раскручивать стек в userspace

- Копирует верхушку стека из kernelspace в userspace на каждый семпл
- Постпроцессинг: парсит DWARF и раскручивает стек уже после записи
- Большой размер трассы: **сотни мегабайт в секунду**
- Обрезает стеки: максимум 64KiB из 2MiB доступного стека

Почему не perf?

Есть фатальный недостаток

Почему не perf?

Есть фатальный недостаток

Нужно пересобирать программы

```
1 $ perf record --call-graph=fp
```

Почему не perf?

Есть фатальный недостаток

Нужно пересобирать программы

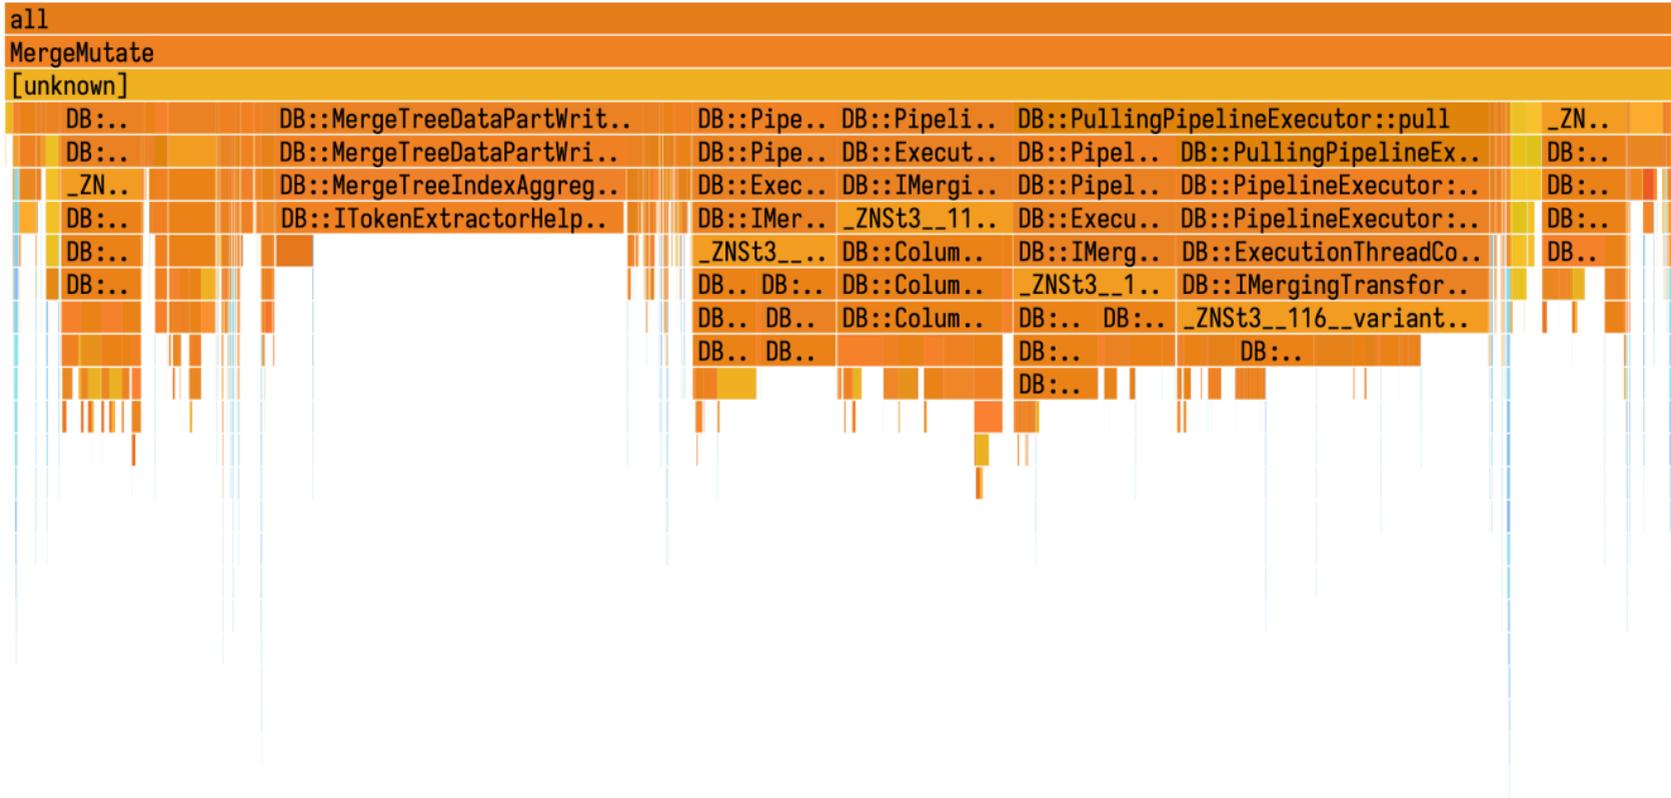
```
1 $ perf record --call-graph=fp
```

Обрезанные стеки

```
1 $ perf record --call-graph=dwarf
```





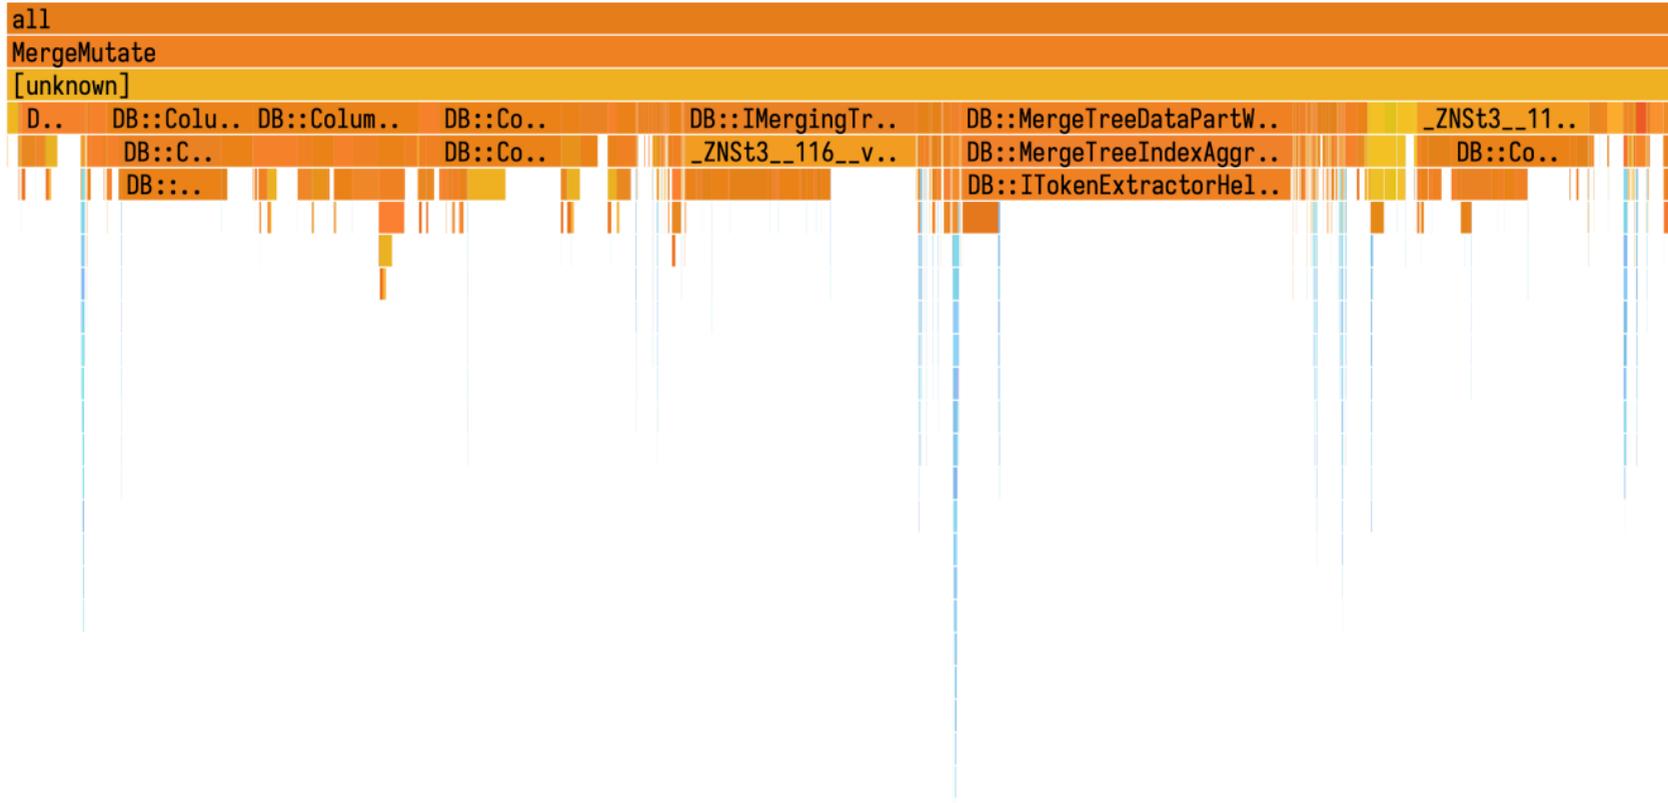


Reverse

Search

Clickhouse flamegraph with DWARF stack size limit of 256 bytes

Showing 1535 frames

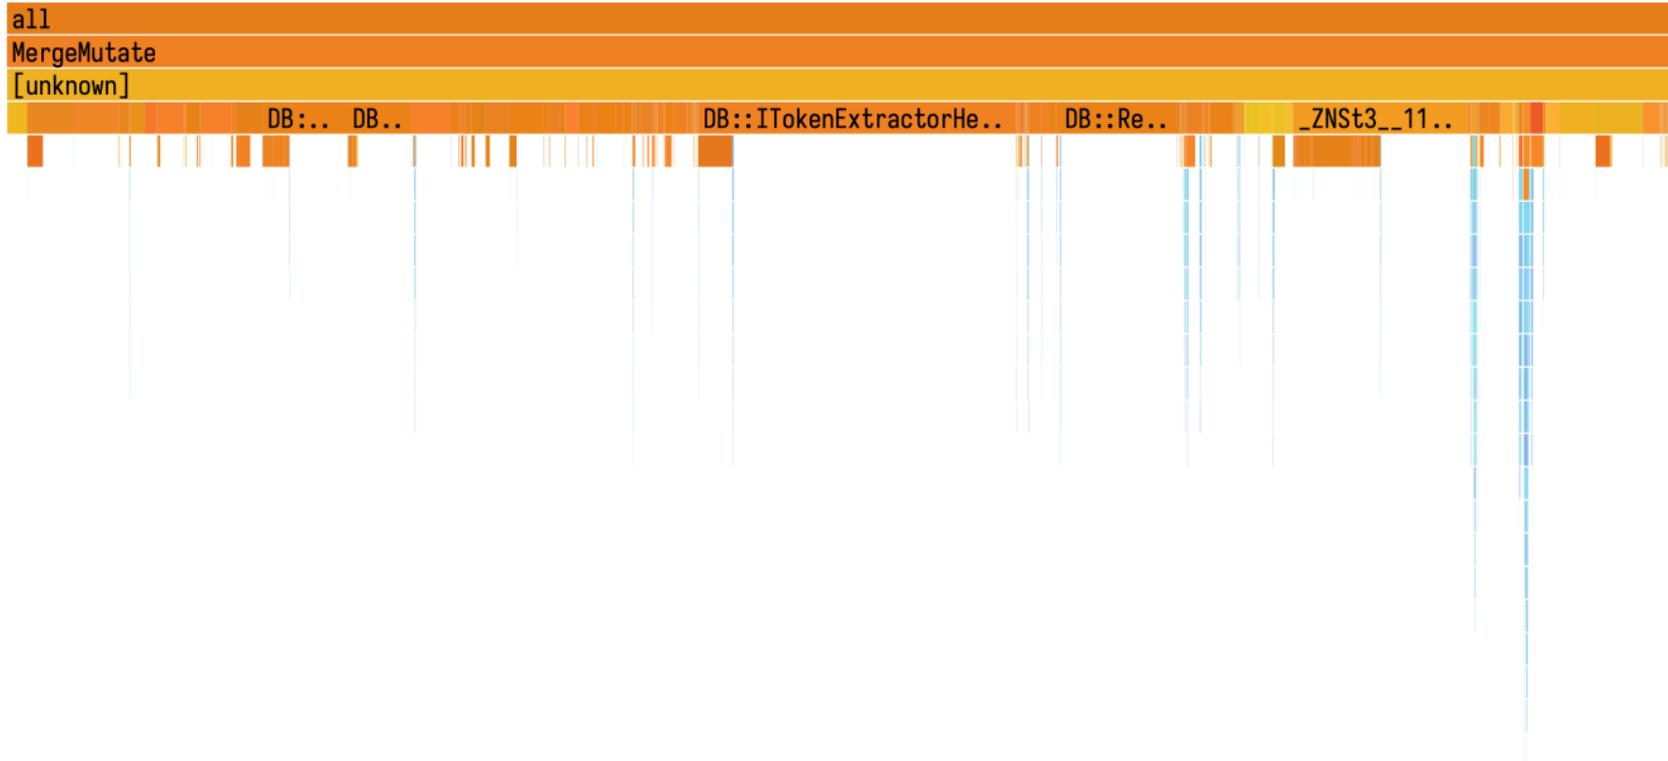


Reverse

Search

Clickhouse flamegraph with DWARF stack size limit of 16 bytes

Showing 1044 frames





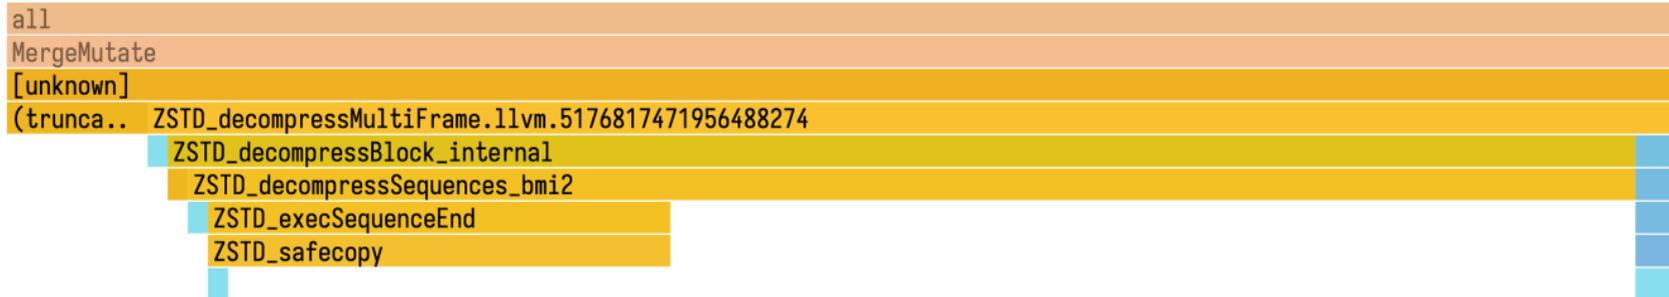


Reverse

Search

Clickhouse flamegraph with DWARF stack size limit of 65528 bytes

Showing 1810 frames

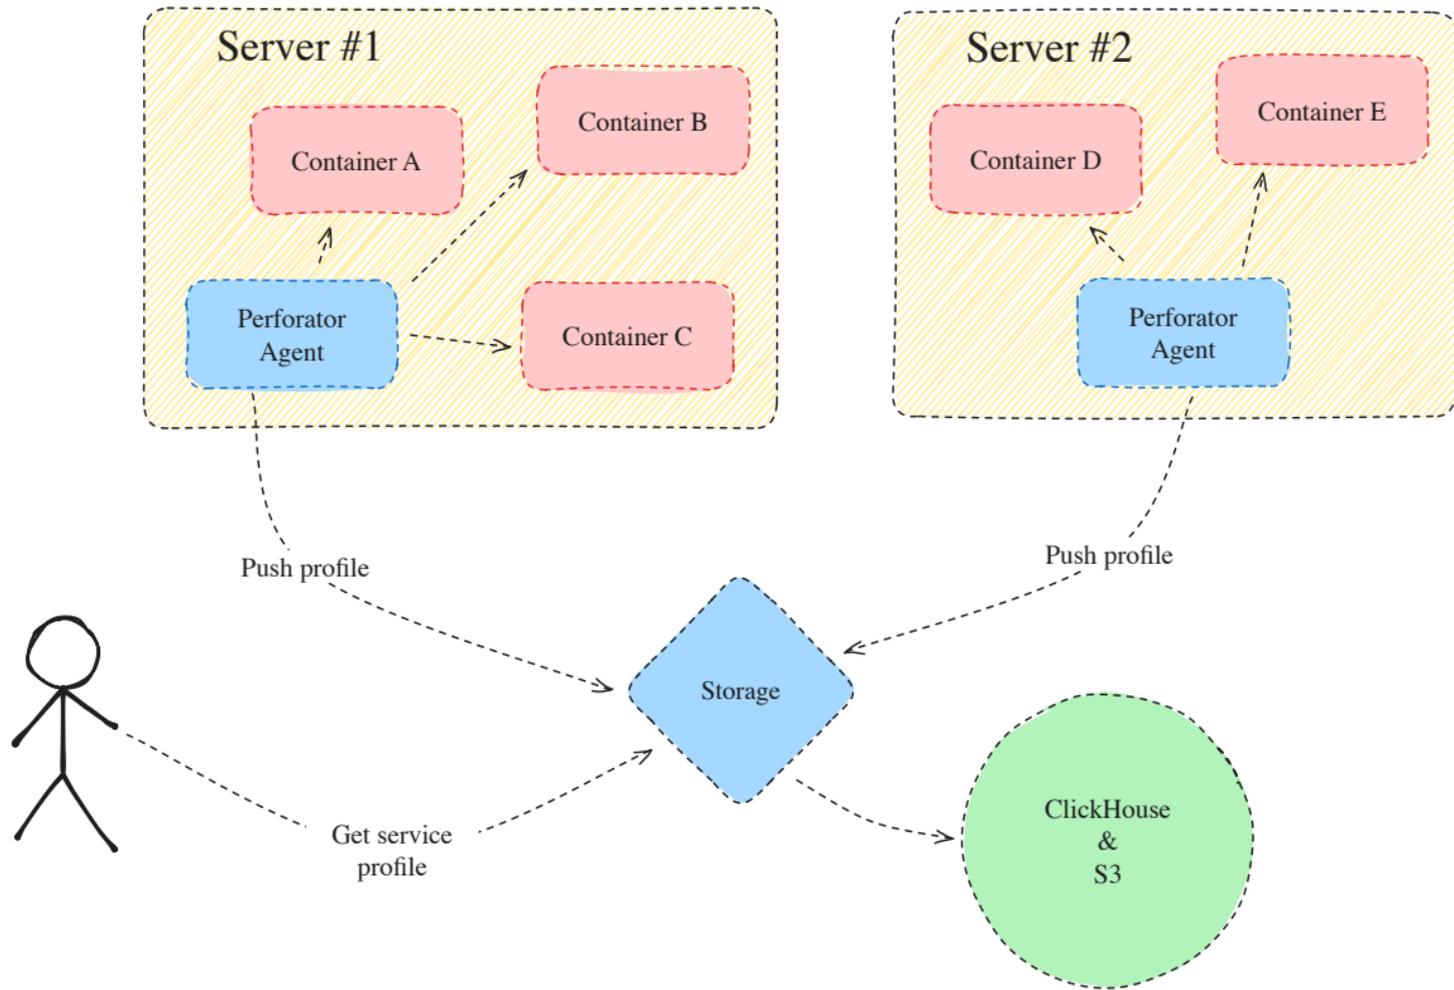


Как быть?

A man in a blue plaid shirt is walking on a city street, looking back over his shoulder at a woman in a red dress who is smiling. Another woman in a light blue top is walking behind him, looking towards him with a surprised expression. The background is a blurred city street with other pedestrians.

Написать ещё один
профилировщик

Включить
-fno-omit
-frame-pointer



Perforator agent

- Выполняется на каждой ноде кластера
- Собирает профили со всей ноды и отправляет в базу профилей
- Можно использовать в качестве классического профилировщика
- Не требует модификации кода или пересборки программ

Perforator

Нужно как-то раскрутить стек в ядре Linux

Perforator

Нужно как-то раскрутить стек в ядре Linux

- Патч в ядро

Perforator

Нужно как-то раскрутить стек в ядре Linux

- Патч в ядро
- Модули ядра

Perforator

Нужно как-то раскрутить стек в ядре Linux

- Патч в ядро
- Модули ядра
- eBPF

Perforator

Нужно как-то раскрутить стек в ядре Linux

- Патч в ядро
- Модули ядра
- eBPF

Немного про eVRF

- Верифицируемые программы для специальной VM внутри Linux
- Гарантированно не содержит UB (~~если только в ядре нет багов~~)

Немного про eVRF

Множество ограничений: не Тьюринг-полные, есть лимит на сложность

- Циклы только на константное число итераций
- Сложно написать бинарный поиск
- Нетривиальные программы нужно долго оптимизировать под верификатор

eBPF meets Linux perf

В Linux есть поддержка вызова eBPF-программы на прерывание от PMU

- Можем построить свой perf
- На каждые N тактов изучаем состояние программы
- Можем понять буквально все про процесс
- Как раскрутить стек?

eBPF meets DWARF?

Если сможем раскрутить через DWARF, то победим. Но как?

eBPF meets DWARF?

Если сможем раскрутить через DWARF, то победим. Но как?

- Нужно выполнить код для **виртуальной машины DWARF**

eBPF meets DWARF?

Если сможем раскрутить через DWARF, то победим. Но как?

- Нужно выполнить код для **виртуальной машины DWARF**
- Посмотрим внимательно на DWARF, который пишут компиляторы

eBPF meets DWARF?

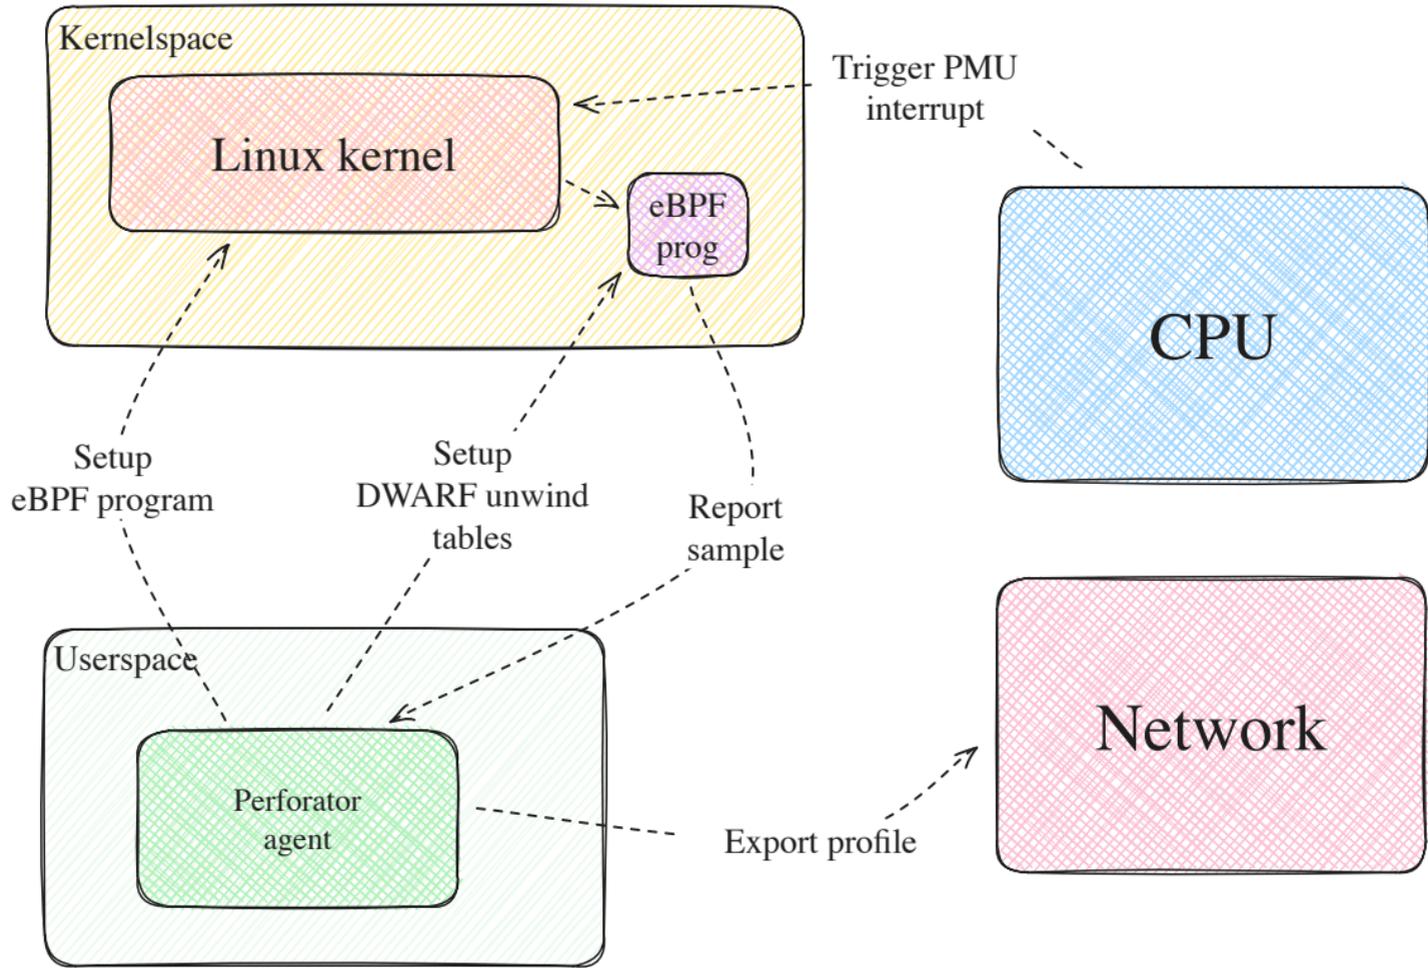
Если сможем раскрутить через DWARF, то победим. Но как?

- Нужно выполнить код для **виртуальной машины DWARF**
- Посмотрим внимательно на DWARF, который пишут компиляторы
- **100% правил раскрутки** – это `rsp+offset` и `rbp+offset`

eBPF meets DWARF?

Если сможем раскрутить через DWARF, то победим. Но как?

- Нужно выполнить код для **виртуальной машины DWARF**
- Посмотрим внимательно на DWARF, который пишут компиляторы
- **100% правил раскрутки** – это `rsp+offset` и `rbp+offset`
- Можно построить облегченную версию таблицы раскрутки без Тьюринг-полноты!



Perforator agent

Про overhead

- CPU: около 0.2% на реальных приложениях
 - Зависит от частоты сбора семплов. У нас 99Hz с одного ядра
- RAM: 1% от памяти хоста
- Сейчас непрерывно профилируем все процессы, без opt-in

Perforator symbolizer

Превращать адреса инструкций в названия функций дорого

- Агенты отправляют адреса и идентификаторы исполняемых файлов
- Символизируем все в одной точке
- Максимально точно показываем заинлайненные функции. Лучше только gdb

Perforator storage

База данных профилей

- Хранилище поверх Clickhouse + S3
- Принимает профили из произвольных источников в формате **pprof**
- Хранит последовательности атомарных профилей. Ключ последовательности – набор меток
- По разным проекциям строит предагрегаты

	18:00	18:01	18:02	24h
node: A container: X service: S	Profile	Profile	Profile	Container x day aggregate
node: B container: Y service: S	Profile	Profile	Profile	Container x day aggregate
node: C container: Z service: S	Profile	Profile	Profile	Container x day aggregate
service: S	Service aggregate	Service aggregate	Service aggregate	Service x day aggregate

```
$ perforator fetch '{
    service = "yandex.search",
    timestamp > "10:00",
    node_id = "server123.yandex.net"
}' -o flamegraph.html
```

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом
- CPU на строчку: сколько каждая строчка сжигает CPU?

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом
- CPU на строчку: сколько каждая строчка сжигает CPU?
- Wall-time profiling: где процесс тратит реальное время?

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом
- CPU на строчку: сколько каждая строчка сжигает CPU?
- Wall-time profiling: где процесс тратит реальное время?
- Чтение `thread_local` значений: профиль про A/B тестам

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом
- CPU на строчку: сколько каждая строчка сжигает CPU?
- Wall-time profiling: где процесс тратит реальное время?
- Чтение `thread_local` значений: профиль про A/B тестам
- Генерация профилей для AutoFDO. PGO без сложных стендов

Perforator. Как использовать?

Cluster-wide профилировщик сделан. Как применять?

- Отладка проблем с производительностью в прошлом
- CPU на строчку: сколько каждая строчка сжигает CPU?
- Wall-time profiling: где процесс тратит реальное время?
- Чтение `thread_local` значений: профиль про A/B тестам
- Генерация профилей для AutoFDO. PGO без сложных стендов
- Minicores: записываем легковесные стектрейсы при фатальных сигналах (включая SIGKILL!)

Что дальше?

Что дальше?

- Верим, что система будет полезна миру

Что дальше?

- Верим, что система будет полезна миру
- Планируем в 2024 году выйти в OpenSource

Что дальше?

- Верим, что система будет полезна миру
- Планируем в 2024 году выйти в OpenSource
- Ждите новостей!

Выводы

Выводы

- Между «вернуть frame pointers» и «отказаться от профилирования» можно не выбирать

Выводы

- Между «вернуть frame pointers» и «отказаться от профилирования» можно не выбирать
- eVRF – новая глава в истории анализа производительности

Выводы

- Между «вернуть frame pointers» и «отказаться от профилирования» можно не выбирать
- eBPF – новая глава в истории анализа производительности
- DWARF не катастрофически сложный

Выводы

- Между «вернуть frame pointers» и «отказаться от профилирования» можно не выбирать
- eBPF – новая глава в истории анализа производительности
- DWARF не катастрофически сложный
- Perforator едет в OpenSource!

Спасибо!

Будем рады ответить на ваши вопросы