ИНФОРМАЦИОННО-УПРАВЛЯЮЩИЕ СИСТЕМЫ РЕАЛЬНОГО ВРЕМЕНИ

Лекция 7:
Оценка наихудшего времени выполнения программ (WCET) - 2

Кафедра АСВК,
Лаборатория Вычислительных Комплексов
Балашов В.В.

Почему важен WCET

- *Время выполнения* программ играет ключевую роль при анализе систем реального времени
- Это время, например, встречается в формуле:

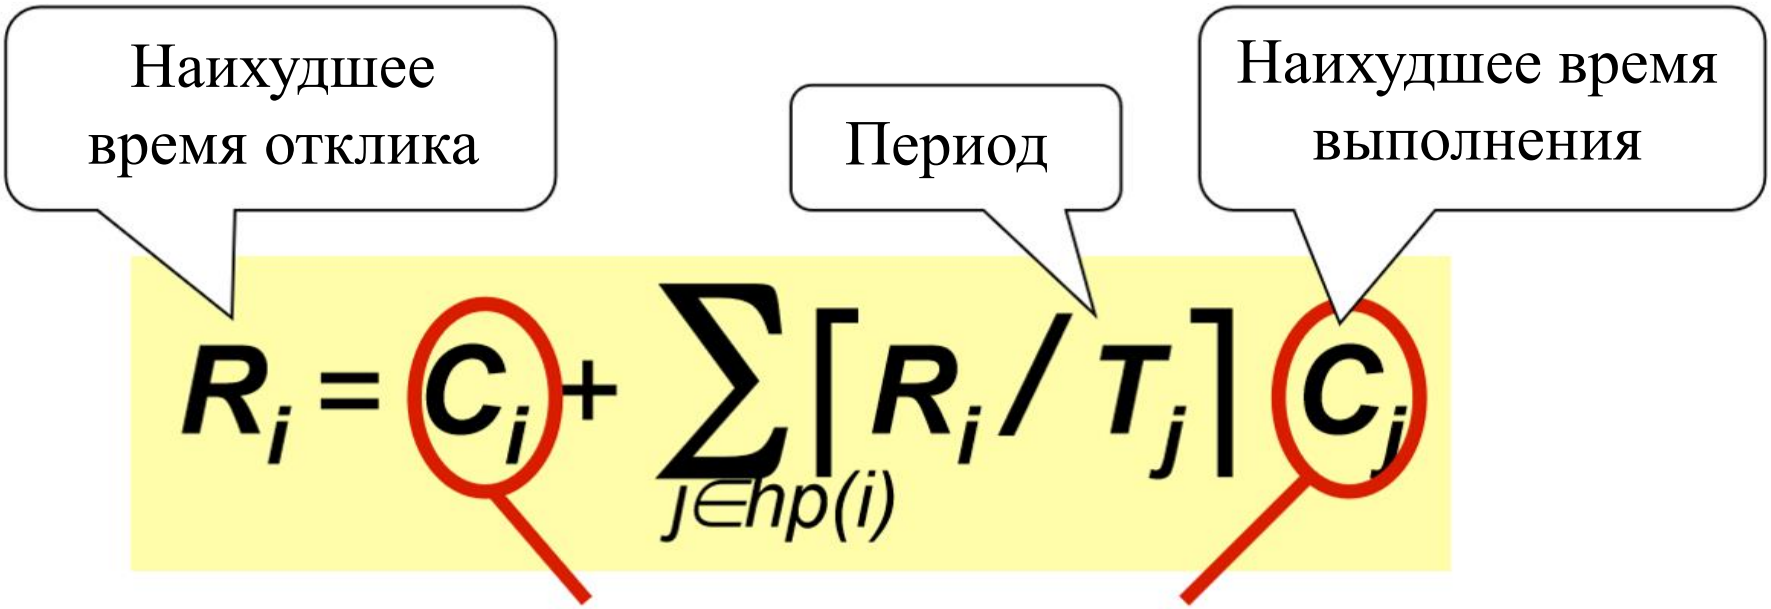

Откуда берутся значения C_i, C_j?

Простейшая вычислительная задача

- Входные данные доступны в момент старта
- Выходные данные готовы в момент завершения
- Нет блокировок в процессе выполнения
- Нет синхронизации или обмена данными в процессе выполнения
- Время выполнения зависит только от:
  - входных данных
  - состояния задачи в момент старта (внешние воздействия отсутствуют)

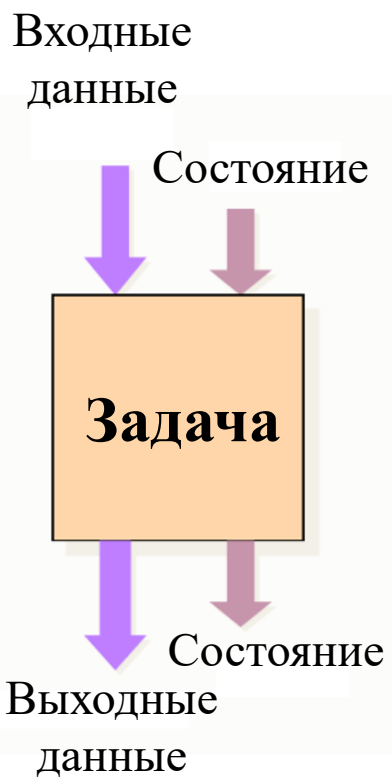

Наихудшее (максимальное) время выполнения

Наихудшее время выполнения программного кода (worst case execution time, WCET) – это максимальное время, которое требуется для выполнения

- данного фрагмента кода
- в данном контексте (входные данные, состояние)
- на заданном аппаратном вычислителе

Чем определяется WCET

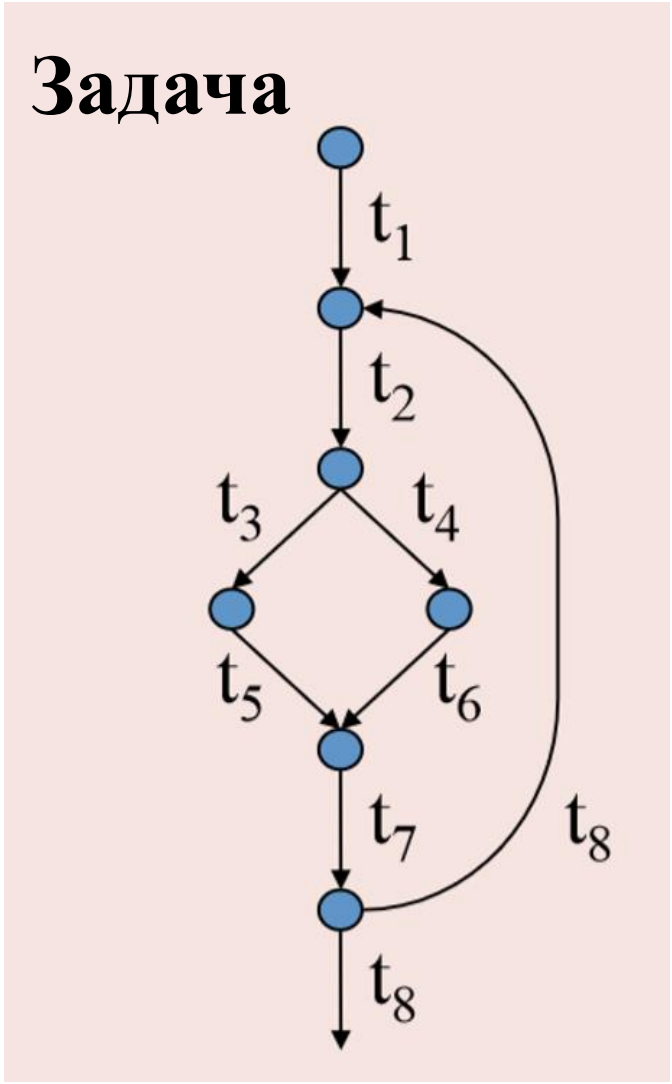

- Возможные последовательности действий задачи (пути выполнения)
- Длительность выполнения каждого действия на каждом допустимом (т.е. практически возможном) пути выполнения

Распределение времён выполнения

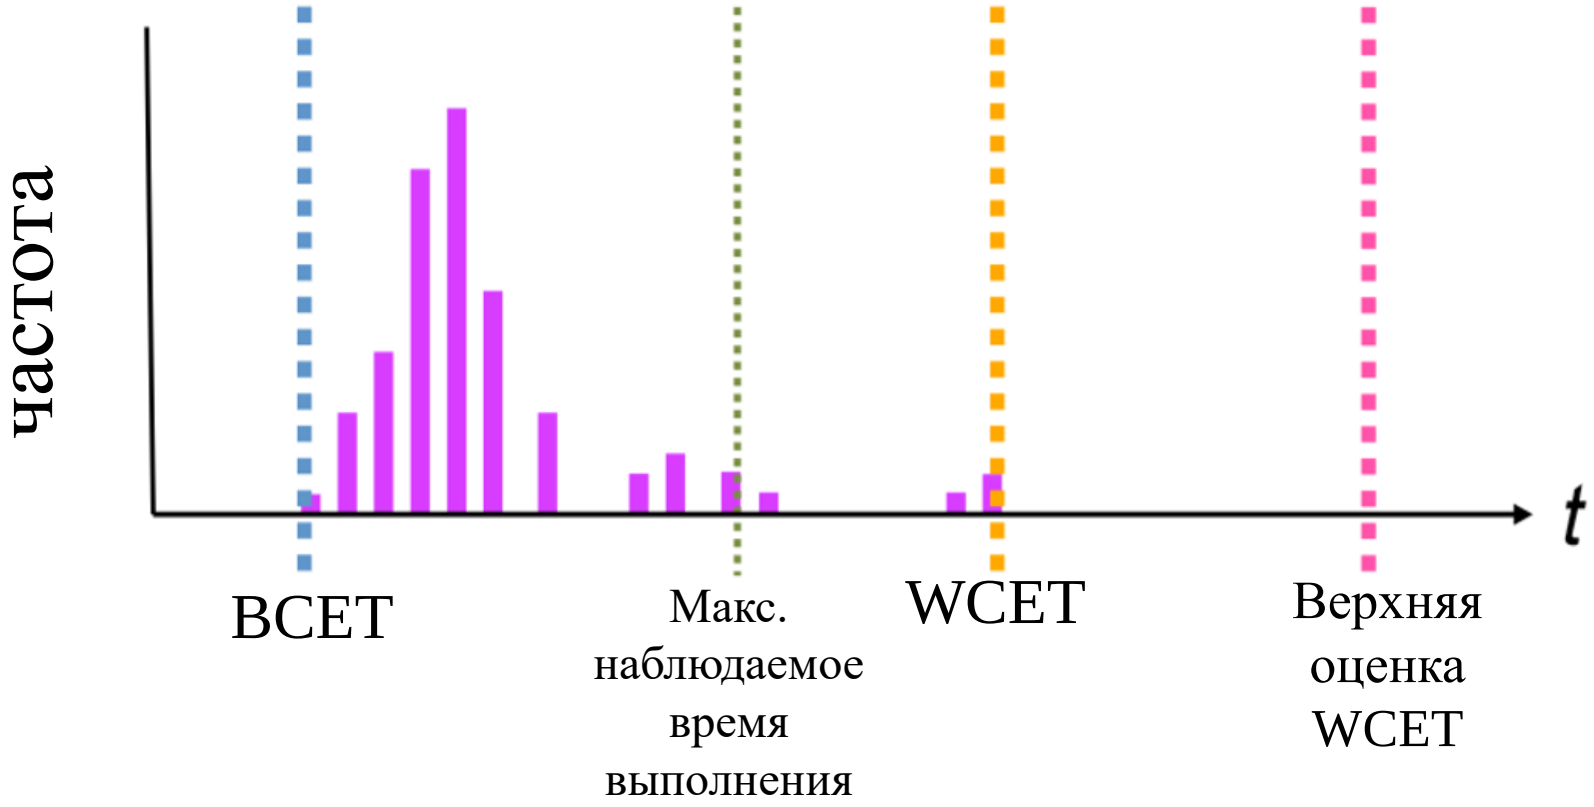

Множество различных времён выполнения
Нетривиальный анализ путей выполнения
Сложное моделирование задержек от аппаратуры

Оптимизация программного кода для временно́й предсказуемости

Что важнее всего в таймингах работы РВ-систем?

- В первую очередь – предсказуемость
  - Предсказуемый WCET
  - Также – предсказуемый BCET
- Производительность – во вторую очередь
- => потребность во временно́й предсказуемости:
  - Аппаратура
  - Программное обеспечение

Почему важен BCET

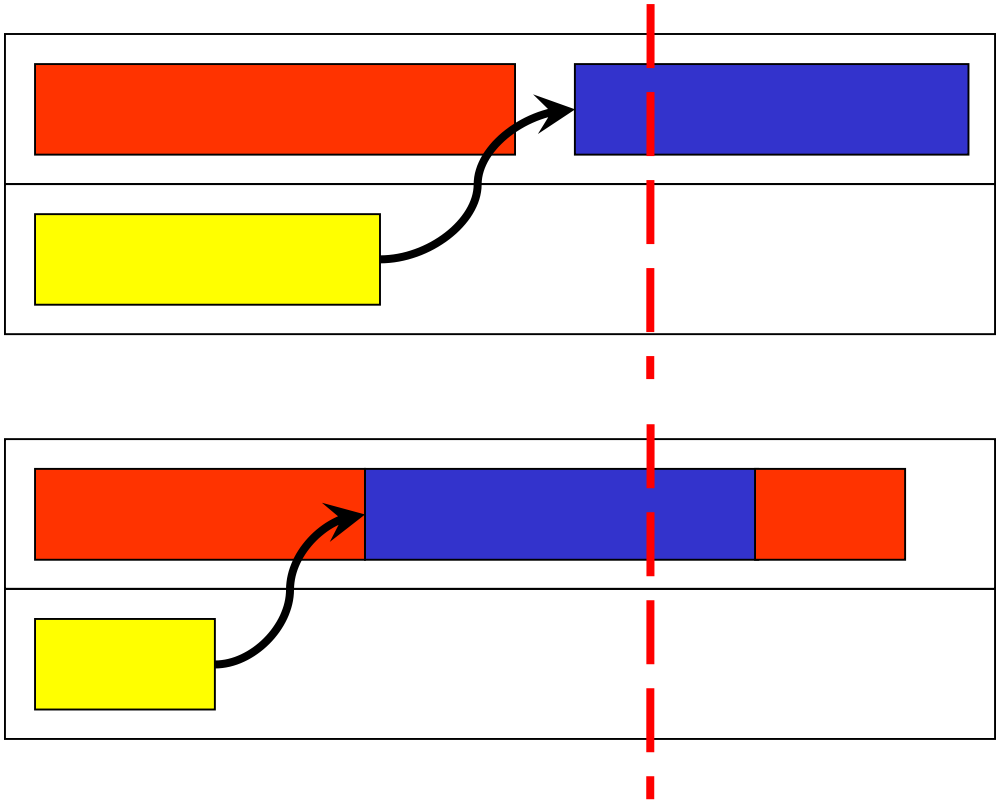

Желтая задача: BCET << WCET

➔ красная задача нарушает директивный срок

Performance Criteria

Write program π with best performance

MEAN

traditional: minimize $\sum_i p_i \cdot c(\pi, \delta_i, \mu)$

probability of input δ_i

machine

input data

WCET

HRT: minimize $\max_i c(\pi, \delta_i, \mu)$

Традиционное программирование

- Цель: хорошая производительность в среднем
- Стратегия: профилировать и оптимизировать производительность на наиболее часто встречающихся наборах входных данных => возможное ухудшение WCET

Причина: сложность неравномерно распределена между наборами входных данных; оптимизация частых сценариев приводит к ухудшению производительности на редких сценариях

WCET-ориентированное программирование

- Стремимся освободить код от ветвлений в зависимости от входных данных
- Минимизируем число действий, выполняемых только для отдельных наборов входных данных

Традиционное vs. WCET-ориентированное программирование

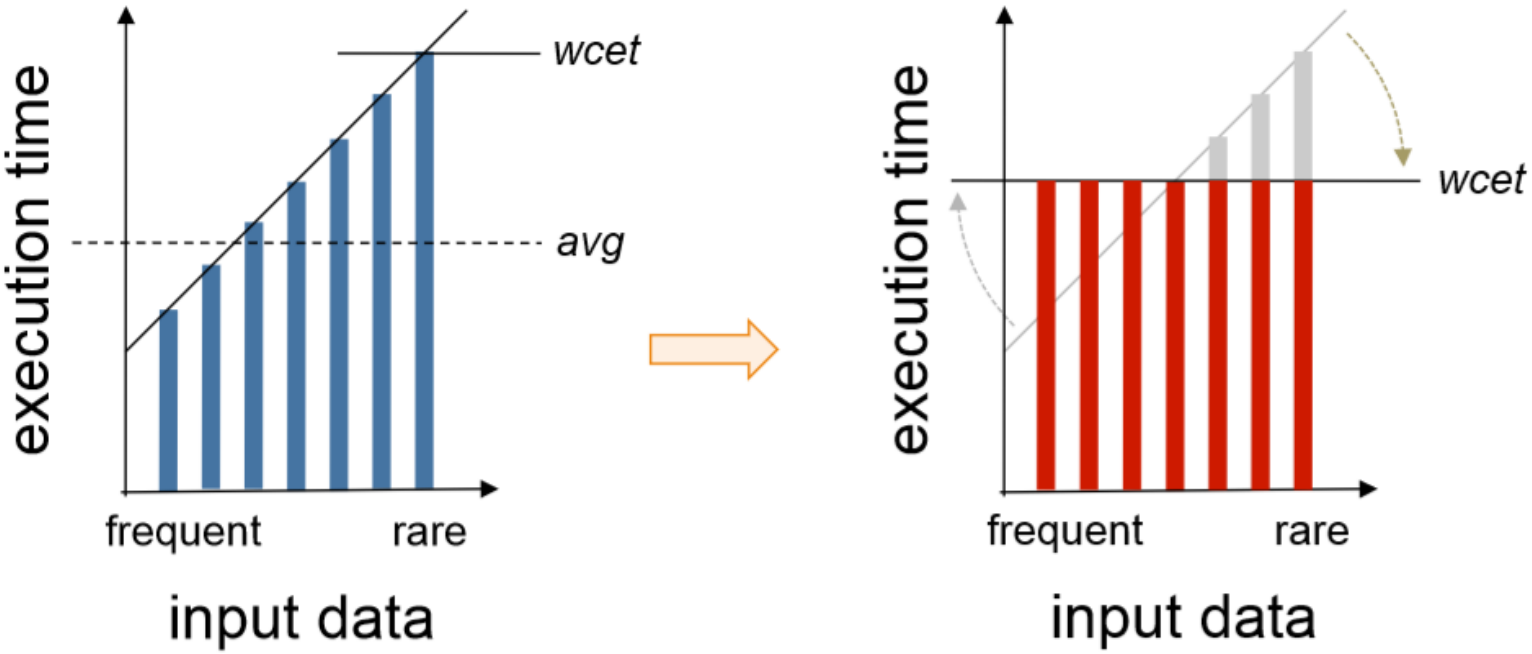

Критерий производительности

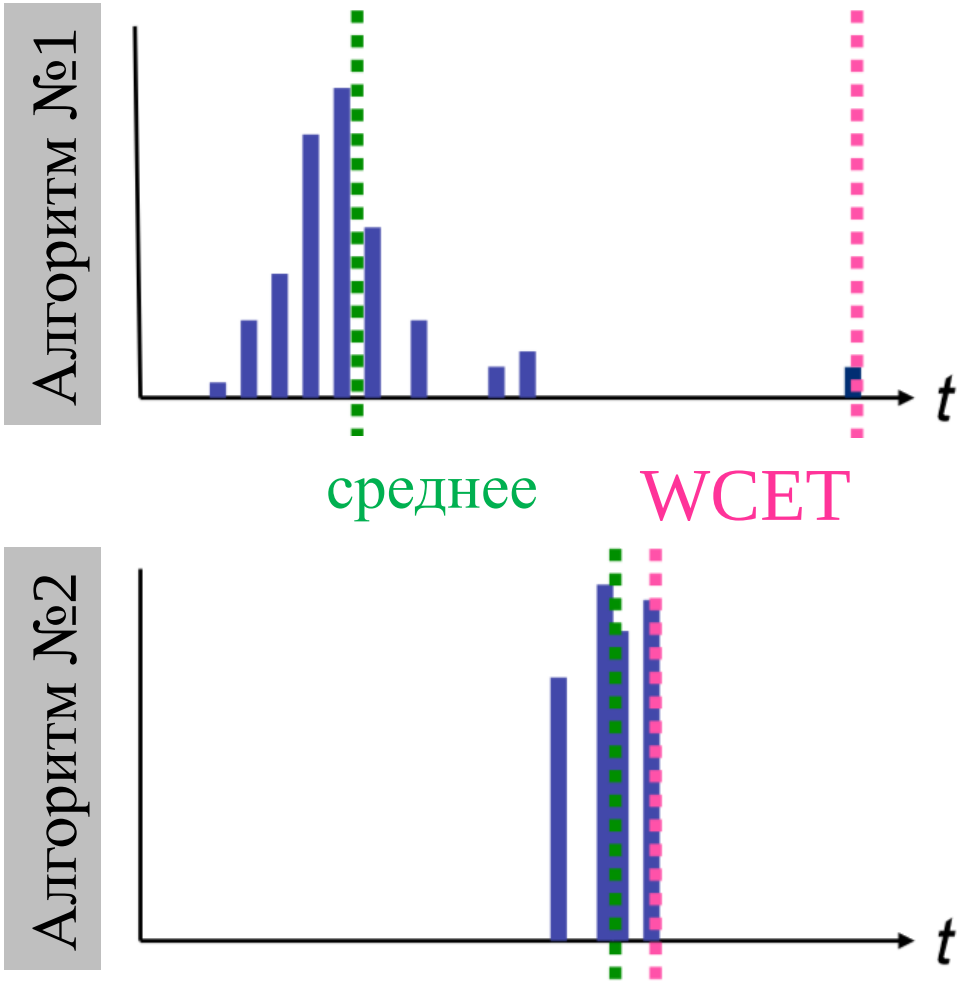

Традиционный подход

WCET-ориентированный подход

Эксперименты

- Традиционный vs. WCET-ориентированный код
- Ветвящийся vs. линейный код

Реализованные алгоритмы:

- Пузырьковая сортировка
- Поиск первого вхождения
- Двоичный поиск
  - одно/два сравнения на каждой итерации

```
static int binSearch_avg(int key, int a[])
{
    int left = 0, right = SIZE-1, idx, inc;
    int found = 0;

    do
    {
        idx = (right + left) >> 1;
        if (a[idx] == key)
        {
            found = 1;
        }
        else if (a[idx] < key)
        {
            left = idx+1;
        }
        else
        {
            right = idx-1;
        }
    } while (!found && (right >= left));

    if (found)
    {
        return idx;
    }
    else
    {
        return -1;
    }
}
```

```
static int binSearch_wcet(int key, int a[])
{
    int left = 0, right = SIZE-1, idx, inc;

    idx = (right + left) >> 1;

    for(inc = SIZE; inc > 0; inc = inc >> 1)
    {
        right = (key < a[idx] ? idx - 1 : right);
        left = (key > a[idx] ? idx + 1 : left);
        idx = (right + left) >> 1;
    }

    return idx;
}
```

Эксперименты

- Традиционное vs. WCET-ориентированное программирование

Алгоритм	Традиционное		WCET-ориентированное	
	Среднее	WCET	Среднее	WCET
Bubble*	599	724	609	663
Find-first*	68	122	103	103
Bin-search	94	124	105	106

* В традиционном варианте: без goto; используется признак раннего завершения

Свойства WCET-ориентированных программ

- WCET меньше, чем у традиционных программ
- Анализ путей проще в связи с устранением/сокращением зависимостей от входных данных
- Оценка WCET проще из-за меньшего числа путей выполнения (или единственного пути)
- Меньше разброс времен выполнения => более стабильна работа системы в целом
- Низкая сложность потока управления => хорошо подходит для управляющих программ, критичных для безопасности
- Нетрадиционные алгоритмы

Стремимся к временно́й предсказуемости

Сокращаем зависимость порядка действий от внешних факторов

$\Rightarrow$ Линейный (single-path) код

- Нет ветвлений по входным данным
- Предикатное выполнение
- Акцент на потоке данных (а не на потоке управления)

WCET-ориентированное программирование + линеаризация кода

- Константное время выполнения
- Низкий WCET
- Тривиальный анализ путей
- Простой анализ WCET

$\Rightarrow$ Полная временна́я предсказуемость

$\Rightarrow$ Приемлемая производительность

Линеаризация: код, оптимизированный под средний случай, замедляется сильнее

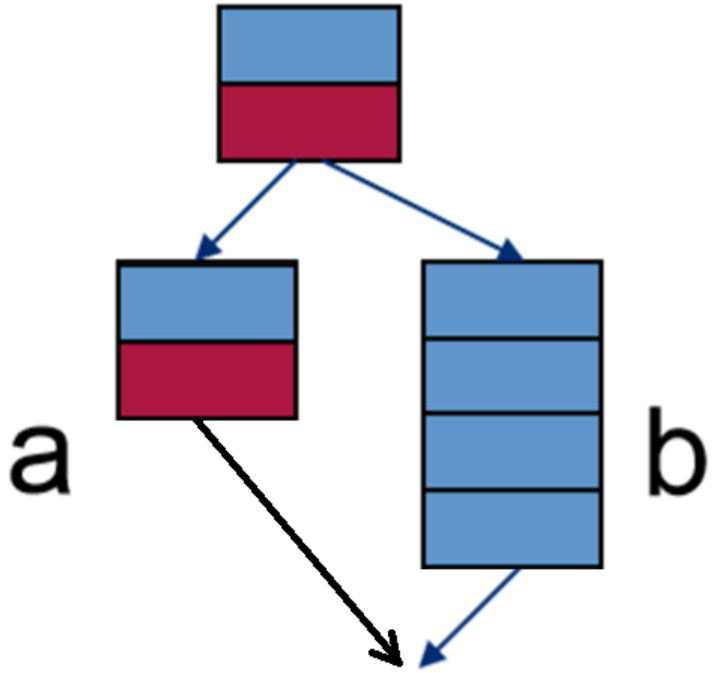

T_{avg}: 4,1 → 8
(x1,95)

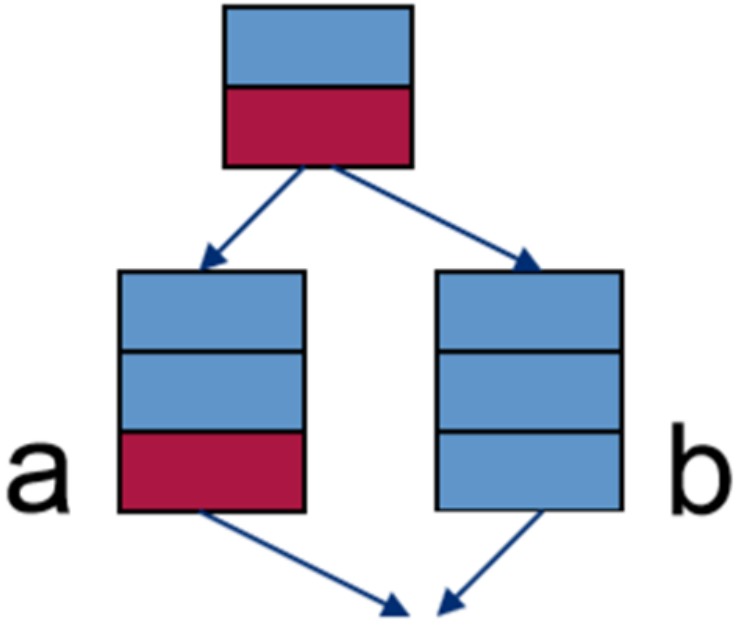

T_{avg}: 5 → 8
(x1,6)

Времена выполнения

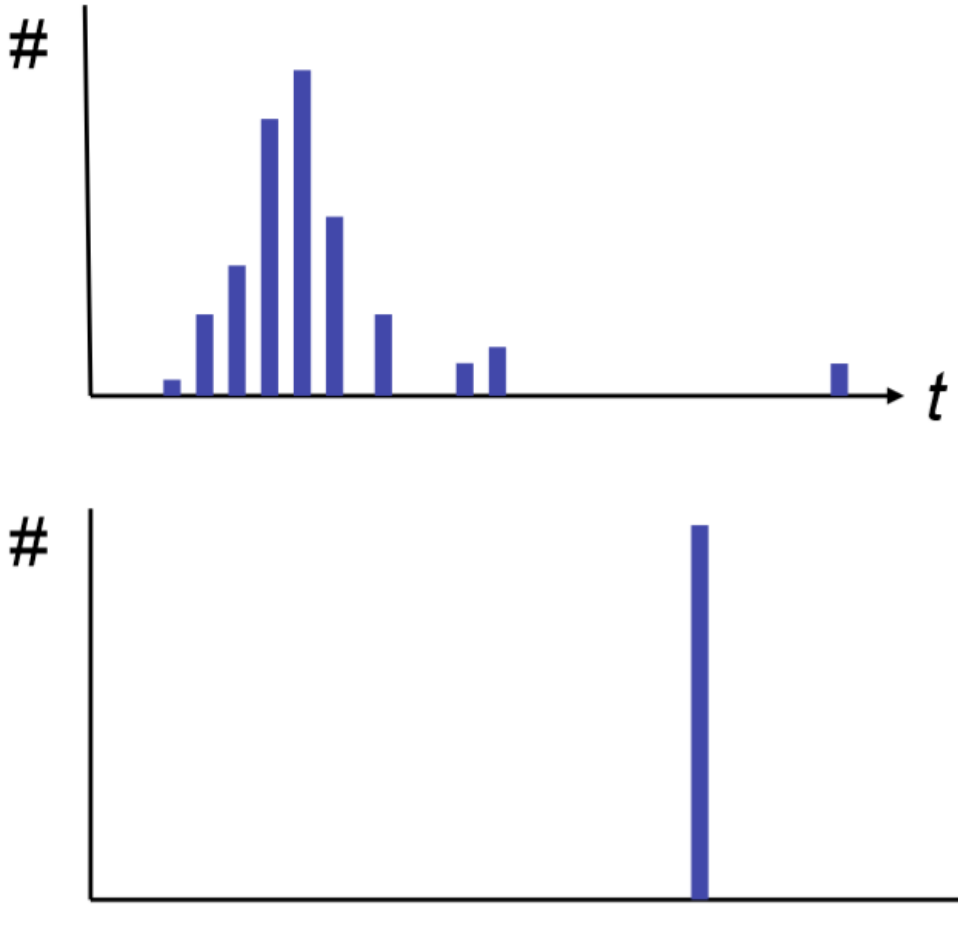

Времена выполнения кода до и после перехода на WCET-ориентированное программирование + линеаризации

Как получить линейный код?

Устранить зависимости по данным из потока управления

- Аппаратура с константными задержками
- Линеаризованный код

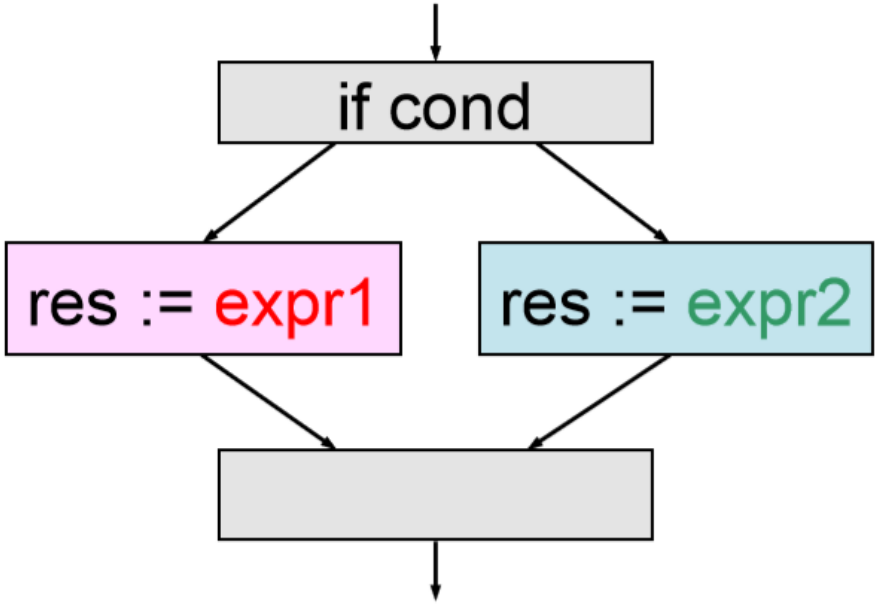

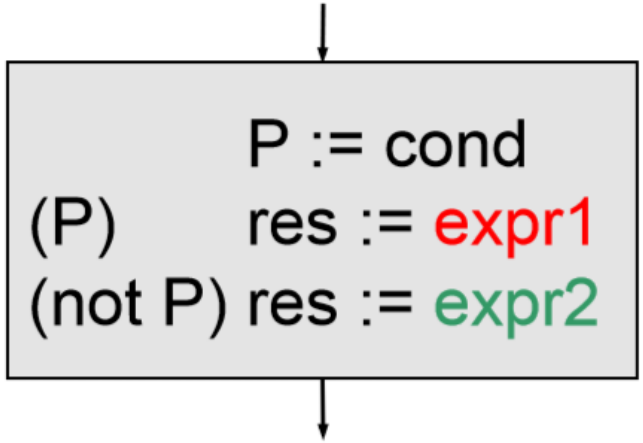

⇨ Предикатное выполнение

Предикатное выполнение

…это условное выполнение или невыполнение команды в зависимости от значения булевой переменой, называемой предикатом

[Hsu et al. 1986]

Выполнение предикатной команды:

- Безусловная выборка команды из памяти
- Предикат истинен => нормальное выполнение команды
- Предикат ложен => команда не изменяет состояние процессора

Ветвящийся vs. предикатный код

Пример кода:

```
if rA < rB then swap(rA, rB);
```

Ветвящийся код

```
        cmplt  rA, rB
        bf     skip
        swp    rA, rB
skip:
```

Предикатный код

```
        predlt Pi, rA, rB
(Pi)    swp    rA, rB
```

Аппаратная поддержка предикатного выполнения

Предикатные регистры

Команды для работы с предикатами (определить, установить, сбросить, загрузить, сохранить)

- Предикатные команды
  - Поддержка полной предикатности: выполнение любых команд управляется предикатами
  - Поддержка частичной предикатности: лишь некоторое подмножество команд могут быть предикатными (например, копирование данных, присваивание значений)

Специфика частичной предикатности

Опережающее выполнение вычислений

- Команды, не являющиеся предикатными, выполняются безусловно
- Их результаты сохраняются во временных переменных
- В дальнейшем предикат определят, содержание какой из временных переменных следует использовать

Пример:

```
(pred)        cmov dest, src1
(not pred)    cmov dest, src2
```

Внимание: команды, вычисляющие значения временных переменных, не должны генерировать исключения (пример: деление на ноль, обращение к недопустимому адресу памяти).

Полностью vs. частично предикатный код

Оригинальный код

```
if src2 ≠ 0 then dest := src1/ src2;
```

Полностью предикатный код:

```
Pred := (src2 ≠ 0)
(Pred) div dest, src1, src2
```

Полностью vs. частично предикатный код

Оригинальный код

```
if src2 ≠ 0 then dest := src1/ src2;
```

Частично предикатный код, попытка 1

```
                Pred := (src2 ≠ 0)
(Pred)          div   tmp_dst, src1, src2
                cmov  dest, tmp_dst
```

Возможно исключение при делении на 0

Полностью vs. частично предикатный код

Оригинальный код

```
if src2 ≠ 0 then dest := src1/ src2;
```

Частично предикатный код

```
                Pred := (src2 ≠ 0)
                mov   tmp_src, src2
(not Pred)      cmov  tmp_src, $safe_val
                div   tmp_dst, src1, tmp_src
(Pred)          cmov  dest, tmp_dst
```

Если src=0, присвоить src безопасное значение (например, 1), чтобы избежать деления на 0

Минимальная поддержка предикатности

- Команда условного копирования:

mov*CC destination*, *source*

Семантика:

if *CC*
then *destination* := *source*
else no operation

If-преобразование с условным копированием

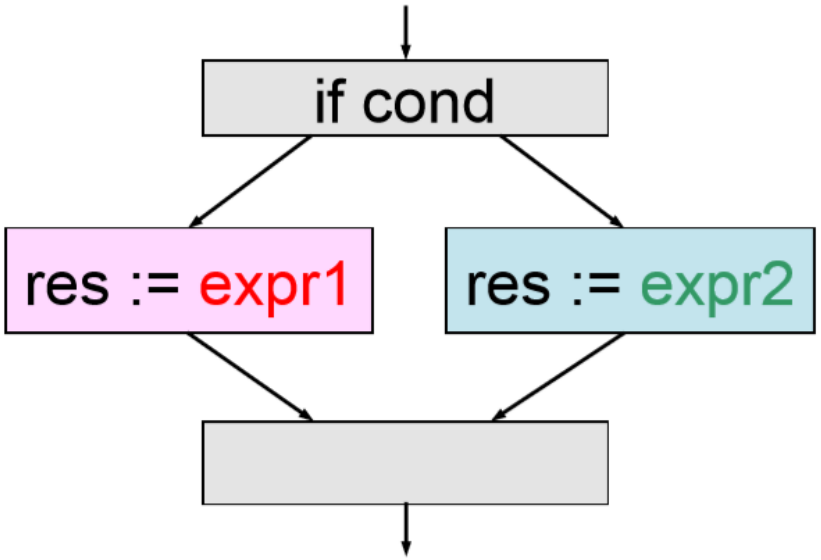

t1 := *expr1'*
t2 := *expr2'*
test *cond*
movT res, t1
movF res, t2

Избегать побочных эффектов

Эмуляция условного копирования

- В архитектурах без поддержки предикатности, условное копирование можно эмулировать при помощи операций с битовыми масками.

Пример:

```
if (cond) x=y; else x=z;
```

```
t0 = 0 – cond;      // fat bool: 0..false, -1..true
t1 = ~t0;           // bitwise negation (fat bool)
t2 = t0 & y;
t3 = t1 & z;
x = t2 | t3;
```

Допущение: переменные всех используемых типов имеют одинаковый размер

Пример:

Пузырьковая сортировка: на входе массив a[SIZE]

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    if (a[j-1] > a[j])
    {
        t = a[j];
        a[j] = a[j-1];
        a[j-1] = t;
    }
  }
}
```

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    t1 = a[j-1];
    t2 = a[j];

    (t1>t2): t = a[j];
    (t1>t2): a[j] = a[j-1];
    (t1>t2): a[j-1] = t;
  }
}
```

Пример:

Пузырьковая сортировка: на входе массив a[SIZE]

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    if (a[j-1] > a[j])
    {
        t = a[j];
        a[j] = a[j-1];
        a[j-1] = t;
    }
  }
}
```

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    cond = (a[j-1] > a[j]);

    (cond): t = a[j];
    (cond): a[j] = a[j-1];
    (cond): a[j-1] = t;
  }
}
```

Пример:

Пузырьковая сортировка: на входе массив a[SIZE]

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    if (a[j-1] > a[j])
    {
        t = a[j];
        a[j] = a[j-1];
        a[j-1] = t;
    }
  }
}
```

```
for(i=SIZE-1; i>0; i--)
{
  for(j=1; j<=i; j++)
  {
    t1 = a[j-1];
    t2 = a[j];

    test (t1>t2);
    movt: a[j-1] = t2;
    movt: a[j] = t1;
  }
}
```

Свойства линейного кода

- Каждое выполнение порождает одну и ту же трассу команд, т.е. одну и ту же последовательность обращений к памяти команд.
- Анализ путей тривиален – существует единственный путь.
- Два выполнения, начинающиеся с одинакового состояния кэша команд, порождают одинаковые последовательности промахов/попаданий в кэш команд.

Линейный код и задержки

Каждое выполнение порождает одну и ту же последовательность (а также количество) выполненных инструкций -> хорошая основа для получения фиксированного времени выполнения.

Команды с неконстантным, зависящим от данных, временем выполнения вызывают флуктуации времени выполнения кода.

Разные начальные состояния памяти (в т.ч. кэша) могут привести к различным задержкам при доступе к памяти команд и данных, а значит к различным временам выполнения кода.

Обеспечение константного времени выполнения

Не позволяем внешним факторам влиять на:

- Последовательность выполняемых команд
- Длительность команд

- Всегда начинать с одного и того же состояния кэша команд, конвейера, логики предсказания ветвлений и т.п.
- Обеспечивать константные задержки при доступе к данным
- Обеспечивать константные длительности всех операций процессора
- Все внешние воздействия (в т.ч. вытеснение задач) должны быть предсказуемыми

<u>Что делать:</u>

- Сбрасывать кэши при старте задач
- Размещать данные по фиксированным адресам
- Избегать сложного вычисления адресов

Константные длительности операций процессора

- Все операции процессора должны быть реализованы так, чтобы выполняться за константное время, независимо от значений операндов (пример: целочисленный сумматор всегда отрабатывает за 1 такт)

- В частности, предикатные команды должны выполняться за константное время. Если предикат ложен, команда выполняется, но её результаты отбрасываются и не изменяют состояние процессора.

- У циклически выполняемых команд в коде должны быть константные значения числа итераций.

Производительность линейного кода

Времена выполнения ветвей, выбираемых в зависимости от входных данных, суммируются в связи с линеаризацией.

- Время выполнения линейного кода довольно велико (по сравнению с оригинальным), если путь выполнения оригинального кода существенно зависит от входных данных

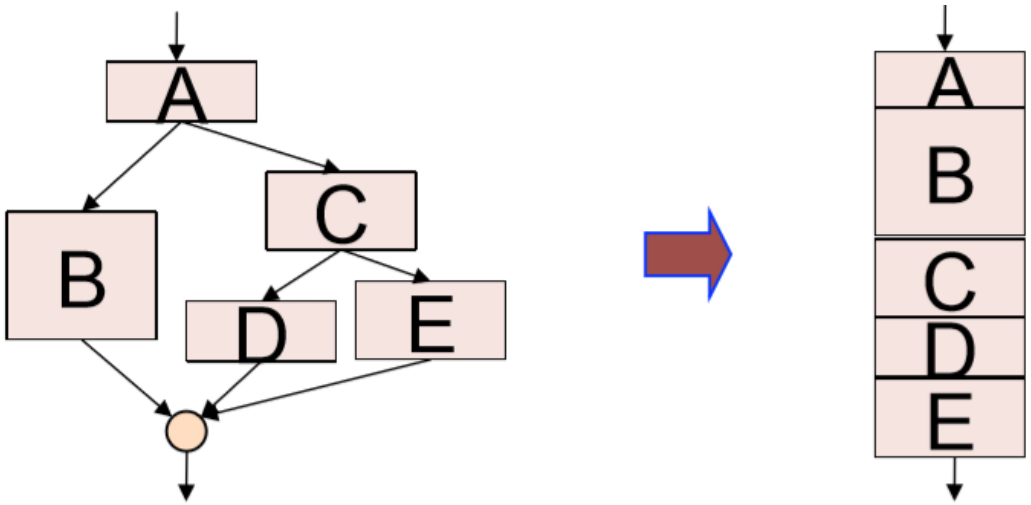

Производительность линейного кода

Процессоры с длинными конвейерами тратят много тактов на перезаполнение конвейера при ошибочном предсказании ветвления.

- Предикатное выполнение может быть «дешевле» ветвления
- Современные компиляторы и процессоры могут использовать предикатное выполнение для улучшения производительности

Пример: ускорение за счет if-преобразования

```
if rA < rB then swap(rA, rB);
```

Ветвящийся код

```
        cmplt  rA, rB
        bf     skip
        swp    rA, rB
skip:
```

Предикатный код

```
        predlt  Pi, rA, rB
(Pi)    swp     rA, rB
```

Выполнение в трёхступенчатом конвейере:

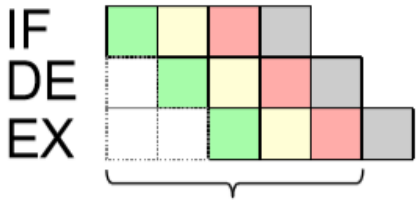

5 тактов

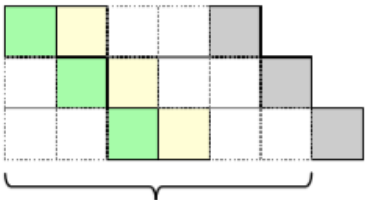

6 тактов

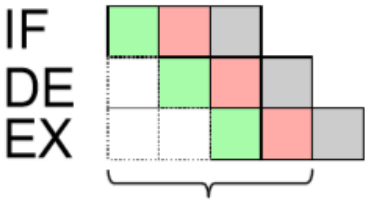

4 такта

Свойства процедуры линеаризации кода

- Полнота: любой участок кода с ограниченным WCET может быть линеаризован
- В линеаризованном коде путь выполнения – единственный
- Анализ WCET тривиален: запустить код и измерить время (при «наихудшем» начальном состоянии системы)
- Код выполняется заметно дольше ветвящегося кода

Времена выполнения

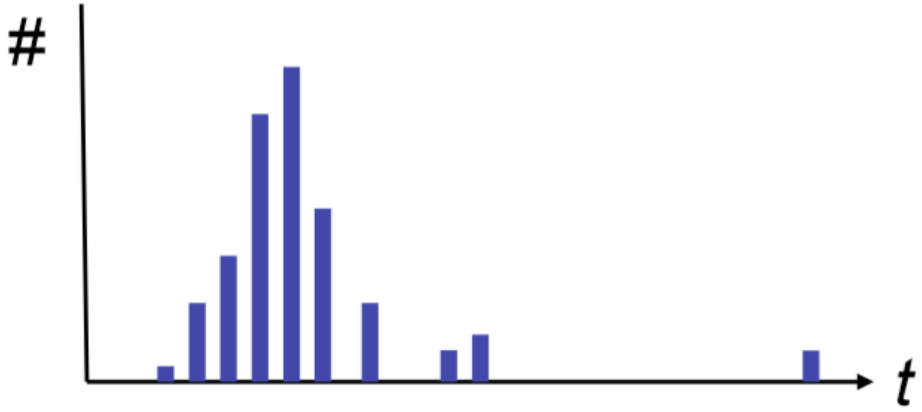

Времена выполнения до и после линеаризации

Оптимизация WCET на этапе компиляции

WCET-aware Code Optimizations

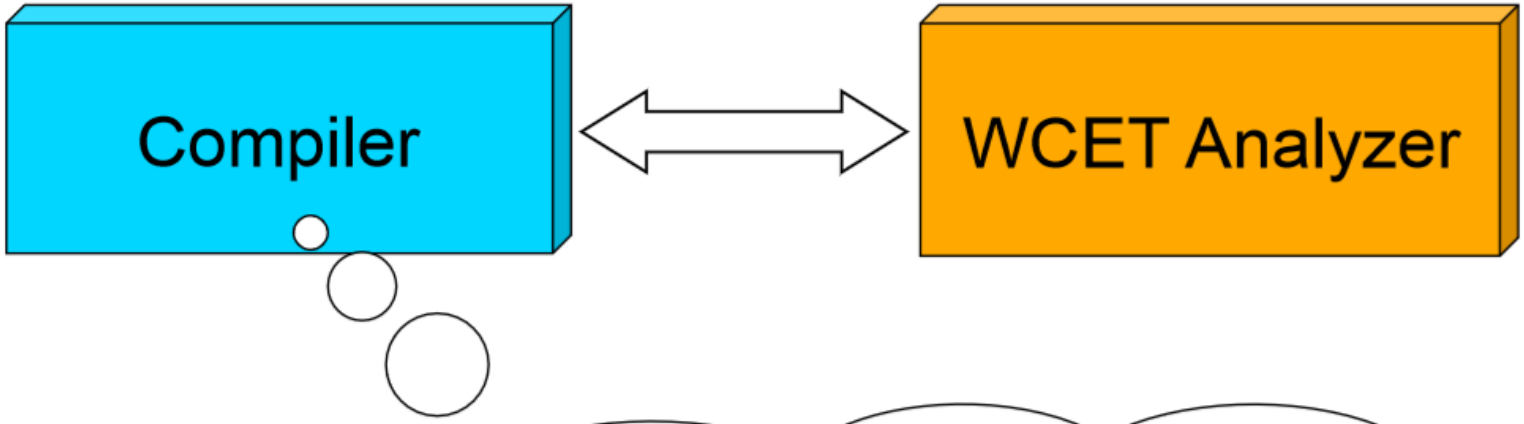

- localize worst-case path,
- select appropriate optimizations,
- identify code locations to apply optimizations

WCET-aware Code Optimizations

Superblock Formation:

…worst case path

superblock:
…block with single entry point

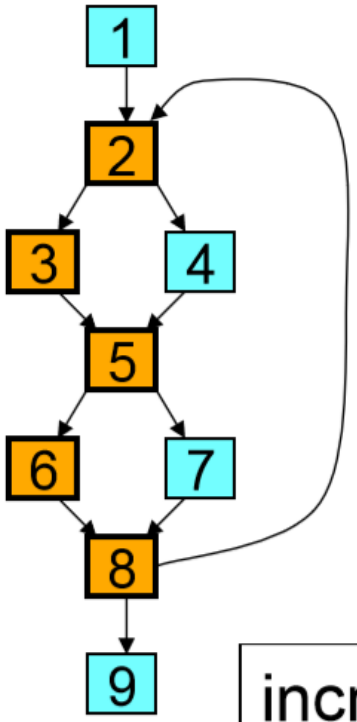

superblock formation

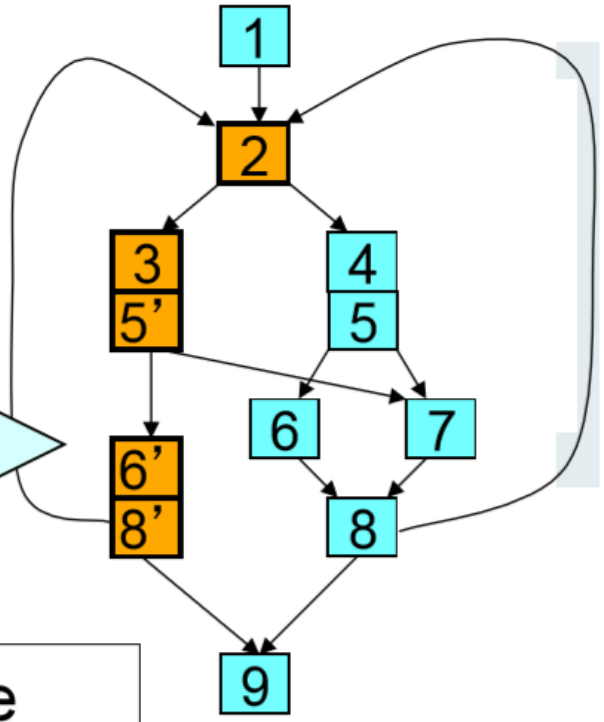

increase of code size
but reduction of WCET

Наихудший путь

- *Внимание:* в результате оптимизации другой путь может стать наихудшим

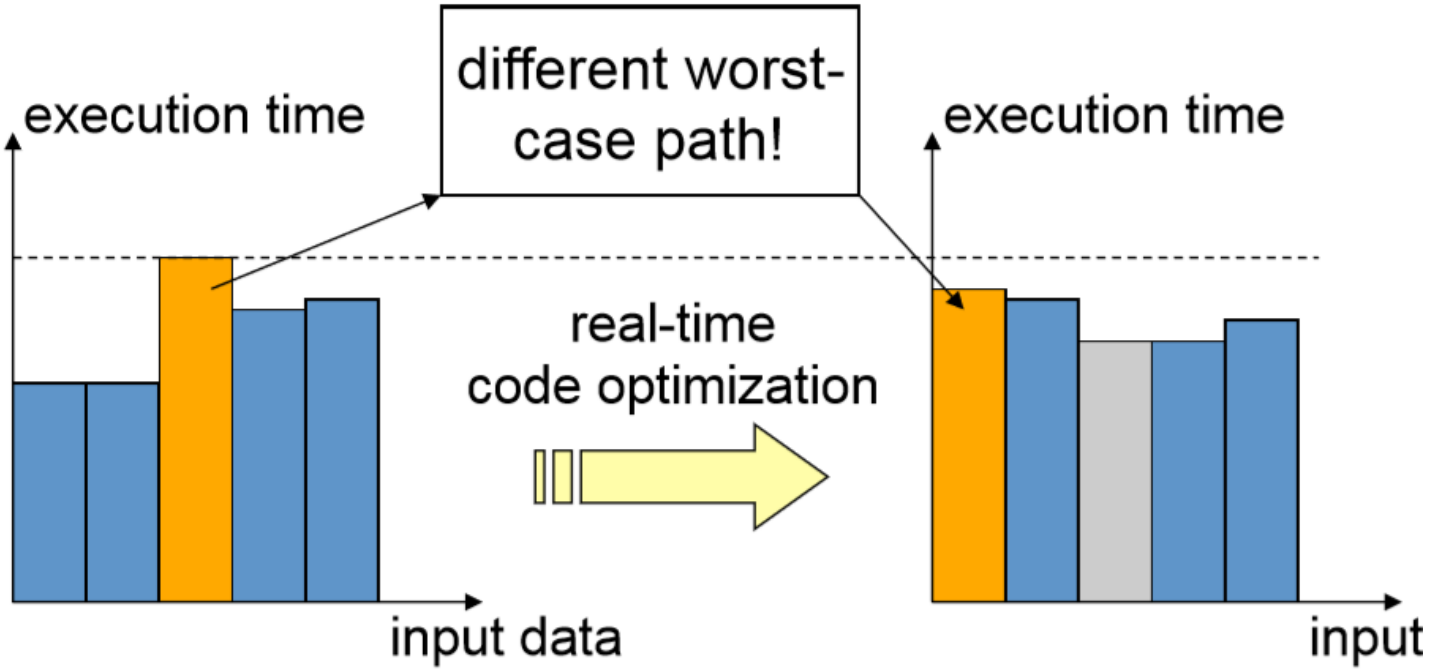

Наихудший путь

- *Внимание:* новый наихудший путь может выполняться дольше, чем первоначальный

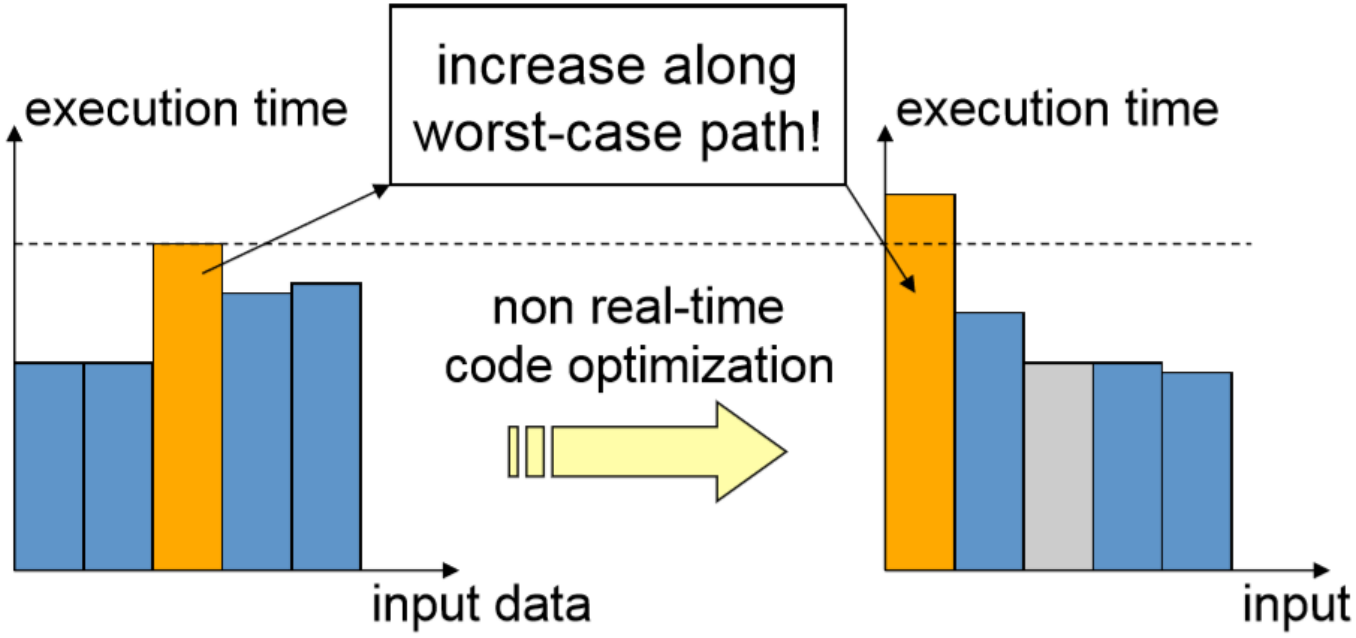

Или всё-таки замерять?

Почему нельзя просто измерить WCET?

- Замер времени выполнения на всех путях выполнения реалистичной программы – на практике невозможен
- При определении тестовой выборки могут быть упущены редкие сценарии выполнения (обработка ошибочных ситуаций и т.п.)
- Выбранные тестовые данные могут не породить самую длинную (по времени) трассу выполнения
- Внутреннее состояние процессора на момент старта измерений может не быть наихудшим

Простые замеры могут послужить источником первоначальной (грубой) *нижней* оценки WCET

С другой стороны...

Не во всех случаях строго необходима безопасная (не заниженная) оценка WCET

- Системы мягкого реального времени (например, мультимедиа)
- Системы, устойчивые к редким превышениям директивных сроков

Для новой аппаратной платформы быстрее всего можно начать именно замеры времени выполнения (а статические методы анализа аппаратных задержек адаптировать долго)
Низкие затраты на аннотирование кода => быстрое получение грубой оценки времени выполнения
Замеры дополняют статический анализ, предоставляя реальные значения задержек
Замеры могут использоваться для уточнения результатов статического анализа WCET

- Моделировать некоторые современные процессоры *действительно* сложно
- Для некоторых задач зависимость времени выполнения от входных данных *по-настоящему* сложна (вещественные числа, массивы и т.п.)
- Люди из промышленности требуют подтверждения теоретических оценок WCET данными «из жизни»

Оценка WCET с помощью измерений

- Информация о таймингах получается путём измерения времени выполнения кода на реальной целевой аппаратуре
- Точки инструментирования кода формируют наблюдаемые извне события, используемые для старта и завершения измерений
- Трасса выполнения содержит собираемую *совместно* информацию о путях в программе и временах их выполнения (путь = последовательность линейных участков)

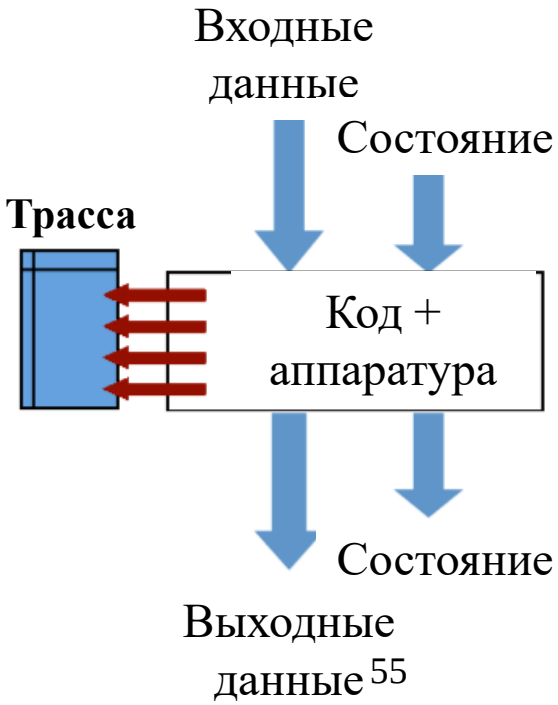

Execution Time Measurements

Goal: Obtain execution time for a path

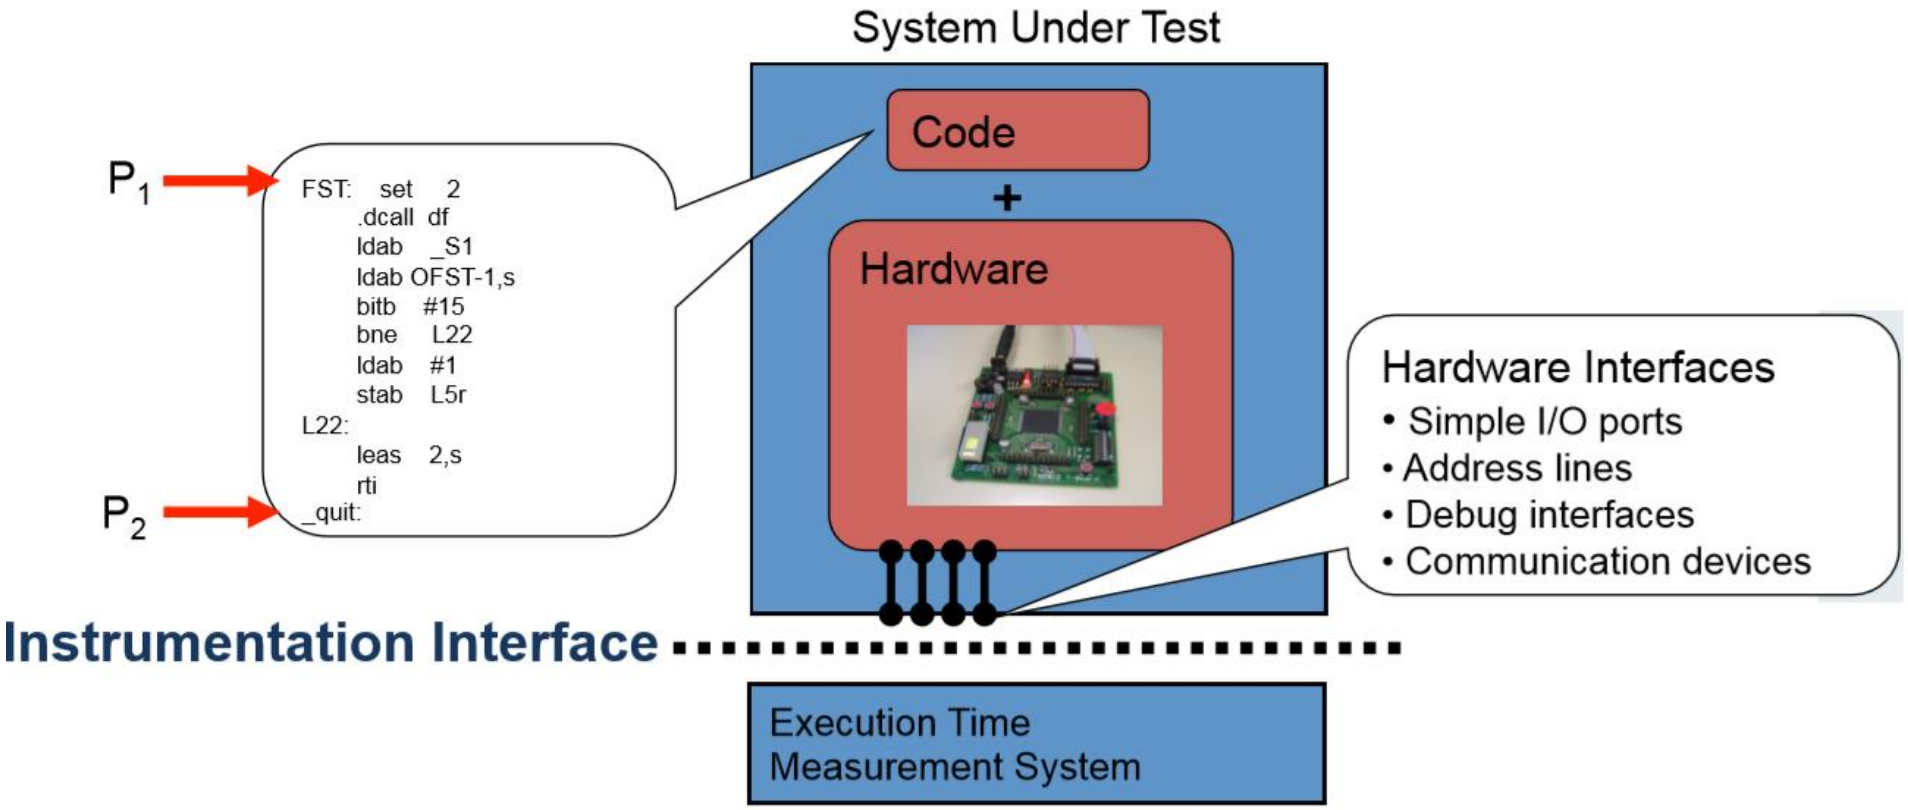

- Необходимо СБРОСИТЬ состояние процессора (кэш, конвейер и т.п.) перед каждым прогоном
- НО: для измерения WCET конкретного пути необходимо специфическое начальное состояние кэша (например, если путь входит в состав второй или более поздней итерации цикла, команды должны *находиться в кэше*)

Методы инструментирования

- Чисто аппаратное инструментирование
- Внешние замеры времени выполнения при помощи программно формируемых сигналов вовне
- Чисто программное (внутреннее) инструментирование

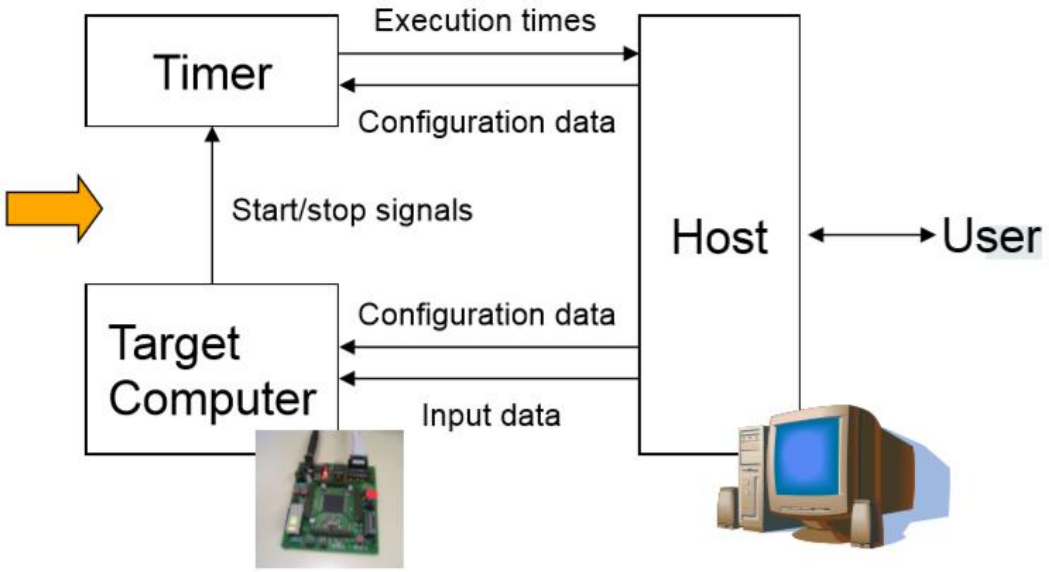

Важные соображения по замерам

Как измерить именно то, что нужно:

- Инструментирование кода не должно изменять путь выполнения или время выполнения программы *непредсказуемым* или *неизвестным* способом. Точки инструментирования должны располагаться в фиксированных местах кода.
- Нужна уверенность в том, что запуски для замеров всегда стартуют с известного требуемого состояния процессора (кэш, конвейер, предсказание ветвлений и т.п.)

Промышленный подход

- Пример промышленного процесса разработки:

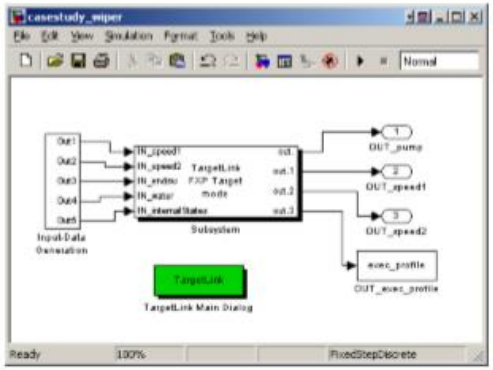

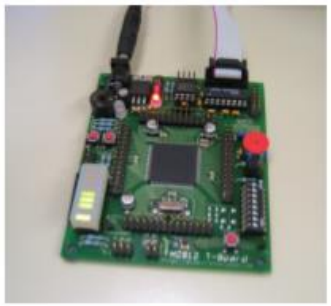

Проектирование

Matlab + Simulink

Matlab + RTW

Тестирование

Платы-прототипы

Аппаратура целевой системы

Внедрение

Аппаратура целевой системы

Промышленный подход – массивы входных данных

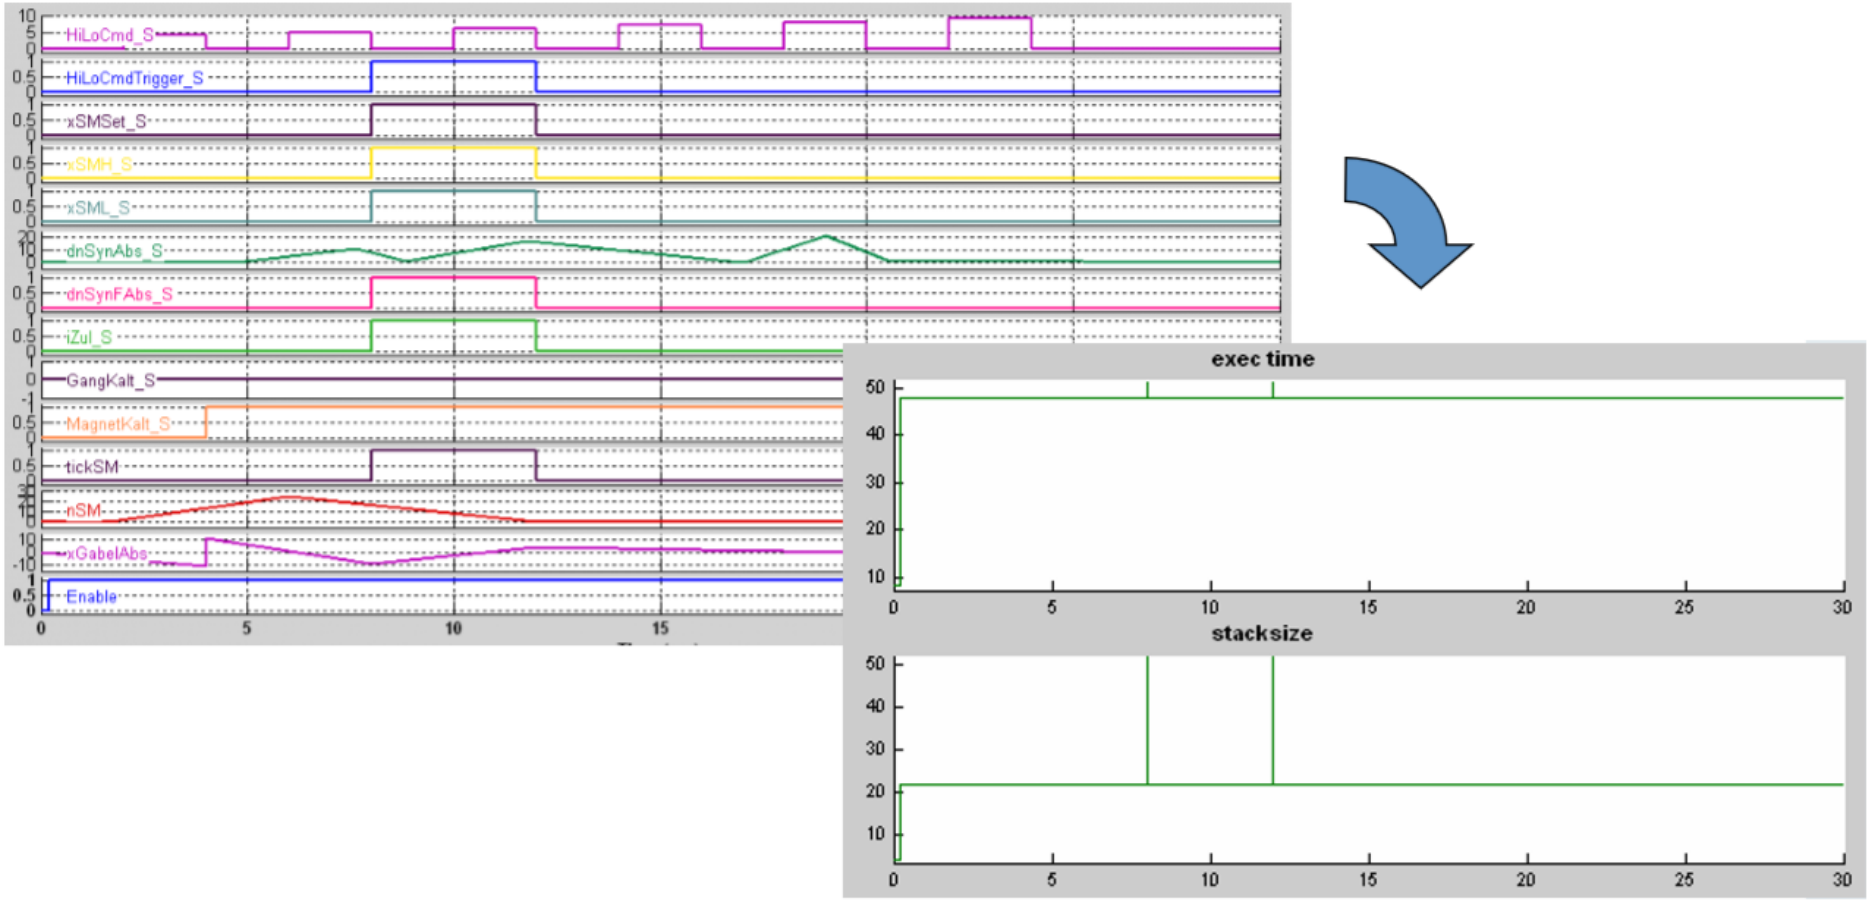

Промышленный подход – случайные данные

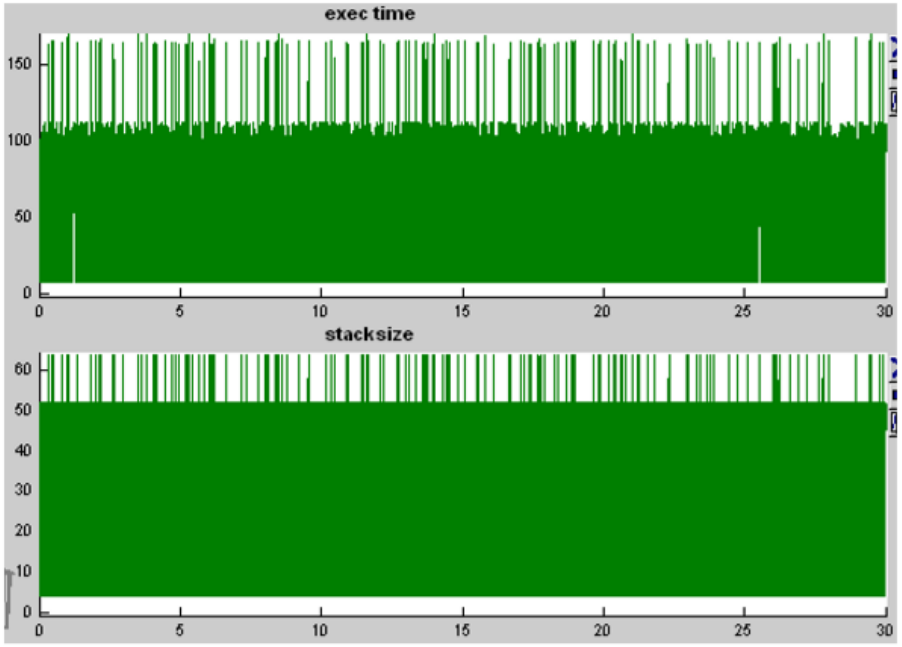

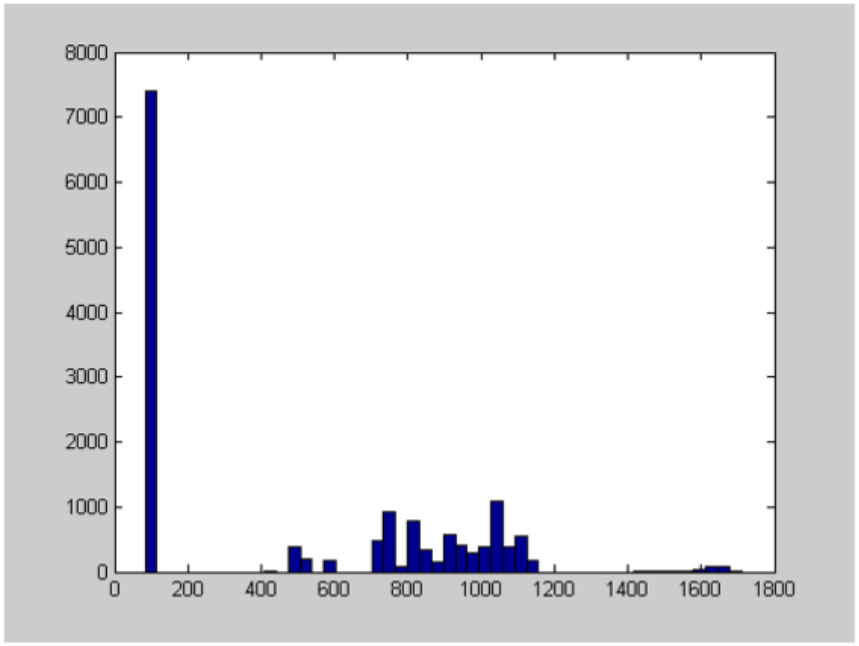

Поиск «наихудших» входных данных – оптимизационная задача

- Массивы входных данных ➔ ограниченный перебор
- Случайные входные данные ➔ случайный поиск
- Как насчёт «умной» оптимизации?

Evolutionary Algorithms (EA)

Gene = an independent property of an individual

Individual = vector of genes

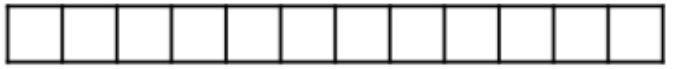

Population = set of a number individuals

Fitness value = chance of survival of an individual

Recombination = mating of two individuals,
exchange of genes

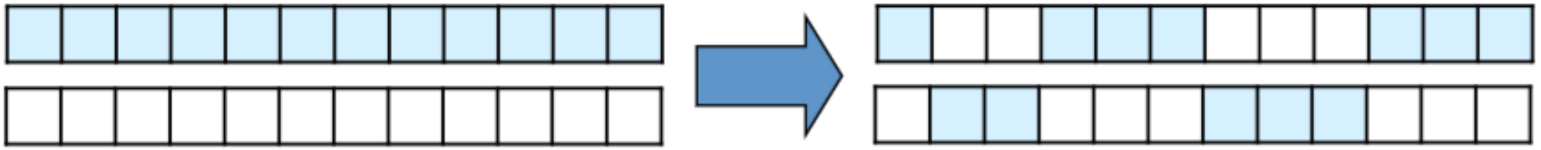

Mutation = random change of a gene

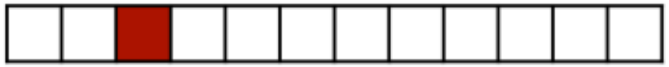

Схема эволюционного алгоритма

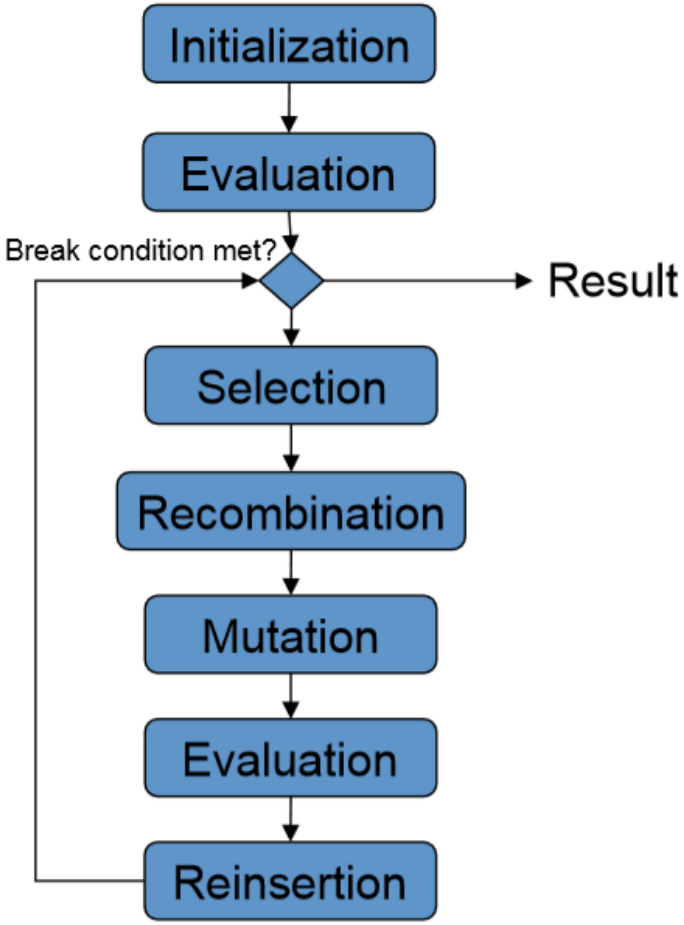

- Отбор: выживание наиболее приспособленных. Отбор рандомизирован и выполняется с учётом значения целевой функции.
- Скрещивание: обмен генами, например одно- или n-точечное скрещивание
- Мутация: рандомизированное изменение генов

Оценка WCET эволюционными алгоритмами

- Ген = значение входной или внутренней переменной
- Целевая функция = измеренное время выполнения (больше значение => особь лучше)
- Результат = «наилучшая особь» = особь (набор данных) с наибольшим временем выполнения программы
- Даёт хорошую, но *небезопасную* оценку WCET

Оценка WCET эволюционными алгоритмами

```
if(x) {
    fast();
} else {
    slow();
}
if(y){
    slow();
} else {
    fast();
}
```

- Старт
  - [0] x = 0, y = 0 -> ET: 40
  - [1] x = 1, y = 1 -> ET: 40
- Скрещивание:
  - [2] x = 0, y = 1 -> ET: 50
  - [3] x = 1, y = 0 -> ET: 30

Алгоритм завершается, если значение целевой функции не улучшается на протяжении заданного числа итераций

Результат применения эволюционного алгоритма

Завышенная

Программа	WCET	WCET SA	WCET EA
Matrix	13,190,619	15,357,471	13,007,019
Sort	11,872,718	24,469,014	11,826,117
Graphics	N/A	2,602	2,176
Railroad	N/A	23,466	22,626
Defense	N/A	72,350	35,226

Заниженная

Нет результата

Точность - ?

SA .... Static analysis
EA .... Evolutionary algorithms

[Mueller, Wegener, RTSS1998]

Выводы

- Оценка WCET – сложная задача, разрешимая (безопасно и с приемлемой точностью) только для некоторых типов *процессоров* и *программ*
- На практике для оценки WCET применяется сочетание формальных методов и измерений
- Система реального времени должна быть устойчива к отдельным/локальным превышениям имеющихся оценок WCET
  - сторожевые таймеры для обнаружения превышения WCET
  - устойчивость к сбросу задачи-нарушителя (и пропуску итерации её выполнения)
  - «растяжимые» периоды выполнения задач для динамической регулировки загрузки процессора

Спасибо за внимание!