

13. Распределение и назначение регистров

13.1 Постановка задачи

13.1.1 Модель памяти

- ◇ В промежуточном представлении с каждой переменной связывается ячейка памяти для хранения ее значений.
- ◇ Эта ячейка называется *абстрактной*, так как с ней связывается *символический адрес*, который может указывать на регистры, стек, кучу, статическую память, причем каждому классу памяти соответствует бесконечно много символических адресов
- ◇ В компиляторах часто используется модель памяти *«регистр – регистр»*.
В этой модели компилятор старается расположить все данные на *символических регистрах* (или *псевдорегистрах*).
В отличие от физических регистров, число которых невелико, псевдорегистров бесконечно много.
При распределении памяти часть псевдорегистров придется отобразить не на регистры, а в память.

13.1 Постановка задачи

13.1.2 Распределение и назначение регистров

- ◇ *Распределение регистров*
отображает неограниченное множество имен (псевдорегистров) на конечное множество физических регистров целевой машины, Это NP-полная задача
- ◇ *Назначение регистров*
отображает множество распределенных имен регистров на физические регистры целевого процессора. Для решения этой задачи известно несколько алгоритмов *полиномиальной сложности*.
- ◇ Во время назначения регистров предполагается, что распределение регистров уже было выполнено, так что при генерации каждой команды требуется не более n регистров (n – число физических регистров).

13.2 Локальное распределение регистров

13.2.1 Постановка задачи



Применения регистров:



На регистры помещаются **операнды и результаты операций**

(при выполнении операции необходимо, чтобы ее операнды находились на регистрах, результат получается на регистре).



Регистры – **временные переменные**

(на регистры помещаются промежуточные результаты при вычислении выражений

если удастся, на них размещаются все переменные, использующиеся в пределах только одного базового блока).



Регистры используются **для хранения глобальных значений**.



Регистры используются для помощи в управлении памятью времени выполнения (например для управления стеком времени выполнения, включая поддержку указателя стека).

13.2 Локальное распределение регистров

13.2.1 Постановка задачи

- ◇ Рассмотрим алгоритм, распределяющий только те регистры, которые предназначены для операндов и временных переменных (остальные регистры зарезервированы).
- ◇ Предположения:
 - ◇ Базовый блок уже оптимизирован (все «лишние» вычисления удалены).
 - ◇ Для каждой операции **OP** существует команда вида
OP reg, reg, reg
(операнды и результат – на регистрах)
 - ◇ В набор команд входят команды:
LD reg, mem (загрузка из памяти на регистр)
ST mem, reg (сохранение значения регистра)
- ◇ Необходимо, чтобы генератор кода минимизировал количество операций **LD** и **ST** в целевом коде

13.2 Локальное распределение регистров

13.2.2 Дескрипторы регистров и переменных

- ◇ *Дескриптор $DR[r]$ регистра r указывает, значение какой переменной содержится на регистре r (на каждом регистре могут храниться значения одного или нескольких имен)*
- ◇ *Дескриптор $DA[a]$ переменной a указывает адрес текущего значения a . Это может быть регистр, адрес памяти, указатель стека*
- ◇ Пусть определена *функция $getReg(I)$* , имеющая доступ ко всем дескрипторам регистров и адресов, а также к другим атрибутам объектов, хранящимся в таблице символов, которая назначает регистры для операндов и результата команды I .
- ◇ Функция *$getReg(I)$* позволяет назначать регистры во время выбора команд

13.2 Локальное распределение регистров

13.2.3 Выбор команд для базового блока



Выбор команд для вычислительной трехадресной инструкции
 $x \leftarrow op, y, z$

1. С помощью функции *getReg()* выбираются регистры R_x , R_y и R_z для x , y и z .
2. Если $DR[R_y] \neq y$ (y не находится на R_y), генерируется команда **LD R_y , y'** ,
где $y' = DA[y]$ (местоположение y в памяти).
3. Если $DR[R_z] \neq z$, а $DA[z] = z'$, генерируется команда **LD R_z , z'** .
4. Генерируется команда **OP R_x , R_y , R_z** .

13.2 Локальное распределение регистров

13.2.3 Выбор команд для базового блока

- ◇ Выбор команды для инструкции копирования $x = y$
Функция *getReg()* всегда выбирает для x и y одни и те же регистры.
Если $DR[R_y] \neq y$, генерируется команда **LD R_y, y'** .
Если $DR[R_y] = y$, ничего не генерируется
Во всех случаях обновляется $DR[R_y]$: x становится одним из значений, находящихся на R_y .
- ◇ Генерация команды запоминания значений переменных, остающихся живыми после выхода из блока.
Если переменная x жива на выходе из блока,
и если в конце блока оказывается, что $DA[x] = R$ (а не x),
требуется генерация команды **ST x, R** .

13.2 Локальное распределение регистров

13.2.3 Выбор команд для базового блока

- ◇ Правила обновления DR и DA после генерации команды
 - ◇ Для команды **LD R , x** :
 - ◆ изменяем $DR[R]$: в R хранится только x ;
 - ◆ изменяем $DA[x]$, добавляя ссылку на R
 - ◇ Для команды **ST x , R**
 - ◆ изменяем $DA[x]$, добавляя ссылку на x
 - ◇ Для команды: **ADD R_x , R_y , R_z** :
 - ◆ изменяем $DR[R_x]$: в R_x хранится x ;
 - ◆ изменяем $DA[x]$: x – только на R_x
 - ◆ удаляем R_x из DA всех переменных, кроме x .
 - ◇ Для команды $x = y$
 - ◆ если $DA[y] \neq R_y$ добавляем команду $LD R_y, y$;
 - ◆ изменяем $DA[x]$ так, чтобы он указывал только на R_y

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$


4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые
при выходе из блока.


Для инструкции 1: $t = a - b$ необходимо сгенерировать три команды:

- ♦ загрузка регистра R_a
- ♦ загрузка регистра R_b
- ♦ вычитание (результат на регистре R_t)



LD R_1, a

getReg() выдает R_1 для R_a



13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

Для инструкции 1: $t = a - b$ необходимо сгенерировать три команды:

- ♦ загрузка регистра R_a
- ♦ загрузка регистра R_b
- ♦ вычитание (результат на регистре R_t)

R_1	R_2	R_3	a	b	c	d	t	u	v
a			a	b	c	d			

LD R_1, a

LD R_2, b

getReg() выдает R_2 для R_b

R_1	R_2	R_3	a	b	c	d	t	u	v
a	b		a, R_1	b, R_2	c	d			

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

Для инструкции 1: $t = a - b$ необходимо сгенерировать три команды:

- ♦ загрузка регистра R_a
- ♦ загрузка регистра R_b
- ♦ вычитание (результат на регистре R_t)

R_1	R_2	R_3	a	b	c	d	t	u	v
a	b		a, R_1	b, R_2	c	d			

LD R_1, a

LD R_2, b

SUB R_2, R_1, R_2

getReg() выдает R_2 для R_t

R_1	R_2	R_3	a	b	c	d	t	u	v
a	t		a	b	c	d	R_2		

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

Для инструкции 2: $u = a - c$ необходимо сгенерировать две команды:

♦ загрузка регистра R_c

♦ вычитание (результат на регистр R_u)

R_1	R_2	R_3	a	b	c	d	t	u	v
a	t		a	b	c	d	R_2		

LD R_3, c

SUB R, R_1, R_2

getReg() выдает

R_3 для R_c и R_1 для R_u

R_1	R_2	R_3	a	b	c	d	t	u	v
u	t	c	a	b	c, R_3	d	R_2	R_1	

u помещается на R_1 , так как значение a , ранее располагавшееся на R_1 , больше внутри блока не используется

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

Для инструкции копирования 4: $a = d$ необходимо сгенерировать одну команду:

♦ загрузка регистра R_d

R_1	R_2	R_3	a	b	c	d	t	u	v
u	t	v	a	b	c	d	R_2	R_1	R_3

LD R_2, d

getReg() выдает R_2 для R_d

R_1	R_2	R_3	a	b	c	d	t	u	v
u	a, d	v	a	b	c	d, R_2		R_1	R_3

В регистре R_2 теперь хранятся и d , и a .

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

Для инструкции 5: $d = v + u$ необходимо сгенерировать одну команду:

♦ сложение, результат на регистр R_d

R_1	R_2	R_3	a	b	c	d	t	u	v
u	a, d	v	a	b	c	d, R_2		R_1	R_3

ADD R_1, R_3, R_1

getReg() выдает R_1 для R_d

R_1	R_2	R_3	a	b	c	d	t	u	v
d	a	v	R_2	b	c	R_1			R_3

После этой команды

- ♦ d хранится только на R_1 , но не в ячейке памяти для d .
- ♦ a хранится только на R_2 , но не в ячейке памяти для a .

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

1 $t \leftarrow -, a, b$

2 $u \leftarrow -, a, c$

3 $v \leftarrow +, t, u$

4 $a \leftarrow d$

5 $d \leftarrow +, v, u$

t, u, v – временные переменные,
локальные для блока,
 a, b, c, d – переменные, живые при
выходе из блока.

В заключение необходимо сохранить живые переменные a и d , значения которых есть только на регистрах

R_1	R_2	R_3	a	b	c	d	t	u	v
d	a	v	R_2	b	c	R_1			R_3

ST $a,$ R_2
ST $d,$ R_1

R_1	R_2	R_3	a	b	c	d	t	u	v
d	a	v	a, R_2	b	c	d, R_1			R_3

13.2 Локальное распределение регистров

13.2.4 Пример

Генерация кода для базового блока:

```
1  t ← -, a, b
2  u ← -, a, c
3  v ← +, t, u
4  a ← d
5  d ← +, v, u
```

t, *u* и *v* – временные переменные, локальные для блока,
a, *b*, *c* и *d* – переменные, живые при выходе из блока.

Сгенерированный код:

```
LD      R1, a
LD      R2, b
SUB     R2, R1, R2
LD      R3, c
SUB     R1, R1, R3
ADD     R3, R2, R1
LD      R2, d
ADD     R1, R3, R1
ST      a, R2
ST      d, R1
```

Код содержит
4 команды **LD**
2 команды **ST**

Все эти команды связаны с множествами *In(B)* и *Out(B)* переменных живых при входе в блок *B* и при выходе из него

6 команд из 10 связаны с обращениями к памяти

13.2 Локальное распределение регистров

13.2.5 Реализация функции *getReg*

R_1	R_2	R_3	a	b	c	d	t	u	v
d	a	v	a, R_2	b	c	d, R_1			R_3
			i	i	i	i			
			o	o	o	o			
			f						

◇ Генерация команды для инструкции *I*

$x \leftarrow op, y, z$

◇ выбор регистров для операндов **y** и **z**

◇ выбор регистра для результата **x**

◇ Выбор регистра R_y для операнда **y**

(регистр R_z для операнда **z** выбирается аналогично).

◇ Если $DA[y]$ ссылается на регистр R , то полагаем $R_y = R$

◇ Если $DA[y]$ не содержит ссылок на регистры, но имеется регистр R , для которого $D[R]$ не содержит ссылок ни на одну переменную, то полагаем $R_y = R$

13.2 Локальное распределение регистров

13.2.5 Реализация функции *getReg*

- ◇ Выбор регистра R_y для операнда y
 - ◇ Если $DA[y]$ не содержит ссылок на регистры и не имеется ни одного регистра R , для которого $DR[R]$ не содержит ссылок ни на одну переменную, то R можно использовать в качестве R_y , если для каждой переменной v , ссылка на которую содержится $DR[R]$, выполняется одно из следующих условий:
 - ◆ $DA[v]$ содержит ссылку не только на R , но и на адрес v ,
 - ◆ v представляет собой переменную x , вычисляемую командой I , и x не является одновременно одним из операндов команды I ,
 - ◆ переменная v после команды I больше не используется.
 - ◇ Если ни одна из перечисленных выше ситуаций не имеет места, то прежде чем использовать R в качестве R_y , необходимо выполнить *сброс регистра*, т.е. команду **ST v , R**

13.2 Локальное распределение регистров


13.2.5 Реализация функции *getReg*

- ◇ Выбор регистра R_x для результата $\mathbf{x}$
 - ◇ Если $DR[R]$ ссылается только на x , то полагаем $R_x = R$
Это можно делать даже тогда, когда x является одним из y или z , так как в одной машинной команде допускается совпадение двух регистров.
 - ◇ Если y не используется после команды I и если $DR[R_y]$ ссылается только на y , то R_y может использоваться в роли R_x .
 - ◇ Если z не используется после команды I и если $DR[R_z]$ ссылается только на z , то R_z может использоваться в роли R_x .
- ◇ Генерация команд для инструкции I
 $\mathbf{x} \leftarrow \mathbf{y}$
Сначала выбирается R_y , как и для операнда инструкции
 $\mathbf{x} \leftarrow \mathbf{op}, \mathbf{y}, \mathbf{z}$, после чего полагается $R_x = R_y$.

13.2 Локальное распределение регистров

13.2.6 Ограничения

- ◇ В примере на рисунке независимое назначение регистров в базовых блоках привело к тому, что для одной и той же переменной **x** в каждом блоке используются разные регистры
- ◇ Если бы *getReg* блока B_3 знала, что в блоке B_1 значение **x** было получено на **R7**, то выделила бы для **x** регистр **R7**, что позволило бы исключить команду загрузки на регистр в блоке B_3
- ◇ Наличие блоков B_2 и B_4 еще больше усложняет проблему, так как возникают различные требования на разных путях



13.3 Глобальное распределение и назначение регистров

13.3.1 Интервалы жизни

- ◇ *Интервалом жизни (ИЖ)* значения w в переменной v называется множество команд программы, начиная с команды, в которой переменная v определяется со значением w , и кончая последней командой, в которой переменная v используется с этим значением.

0	LD	R0	...		R_0	[0,10]
1	LD	R1	R0 (0)		R_1	[1,6]
2	LD	R2	2		R_1	[6,7]
3	LD	R3	R0 (@x)		R_1	[7,8]
4	LD	R4	R0 (@y)		R_1	[8,9]
5	LD	R5	R0 (@z)		R_1	[9,10]
6	MUL	R1	R1 R2		R_2	[2,6]
7	MUL	R1	R1 R3		R_3	[3,7]
8	MUL	R1	R1 R4		R_4	[4,8]
9	MUL	R1	R1 R5		R_5	[5,9]
10	ST	v	R0 (0)			

13.3 Глобальное распределение и назначение регистров

13.3.2 Построение интервалов жизни



Построение множеств переменных, живых на выходе из каждого блока. Это задача анализа потока данных. Методом итераций решается система уравнений

$$LiveOut[B] = \bigcap_{s \in Succ(B)} (use_s \cup (LiveOut[S] - VarKill_s)) \quad (1)$$

где $LiveOut(B)$ – множество переменных, живых на выходе из B ,
 $LiveIn(B)$ – множество переменных, живых на входе в B ,
 $use(B)$ – множество переменных блока B , которые используются в B до их переопределения в B ,

$VarKill_B$ – множество переменных блока B , которые переопределяются в B (оно обозначалось как def_B).



Решив методом итераций систему (1),
получим $LiveOut(B)$ для всех B .


13.3 Глобальное распределение и назначение регистров

13.3.2 Построение интервалов жизни

- ◇ **Исследование отношений между различными определениями и использованиями.** Нужно построить множества всех определений, достигающих одного и того же использования (*UD-цепочки*), и всех использований, которые достигаются одним и тем же определением (*DU-цепочки*).
- ◇ Такое построение удобно проводить в *SSA*-форме, так как в ней каждое имя определяется только один раз, каждое использование ссылается на единственное имя, а объединение имен обеспечивается с помощью ϕ -функций. Для программы в *SSA*-форме требуемая группировка имен достигается за один просмотр.
- ◇ Алгоритм объединения имен анализирует каждую ϕ -функцию и строит объединение множеств, связанных с каждым ее параметром, и множества, связанного с определяемой ею переменной. Это объединение и представляет интервал жизни.
- ◇ **После обработки всех ϕ -функций строится отображение *SSA*-имен на имена интервалов жизни.**

13.3 Глобальное распределение и назначение регистров

13.3.3 Построение интервалов жизни. Пример



Фрагмент кода
в SSA-представлении

Тот же фрагмент, переписанный в
терминах интервалов жизни

13.3 Глобальное распределение и назначение регистров

13.3.4 Оценка стоимости сброса

- ◇ Стоимость сброса складывается из следующих трех компонент:
 - ◇ стоимость вычисления адресов при сбросе
 - ◇ стоимость операций доступа к памяти
 - ◇ оценка частоты выполнения
- ◇ Для хранения сброшенных значений во фрейме процедуры выделяется специальная область.
Это позволяет свести к минимуму стоимость вычисления адресов при сбросе, исключив использование косвенной адресации и дополнительных регистров для вычисления адреса сбрасываемого значения.
- ◇ Интервал жизни, который содержит только команды загрузки регистра и его сохранения может иметь ***отрицательную стоимость сброса*** в случае, когда обе команды обращаются к одному и тому же адресу памяти. Такие ситуации могут возникнуть вследствие исключения избыточных вычислений.

13.3 Глобальное распределение и назначение регистров

13.3.4 Оценка стоимости сброса

- ◇ Чтобы учитывать частоту выполнения базовых блоков в графе потока управления, каждый базовый блок снабжается *аннотацией*, содержащей оценку стоимости его выполнения (профилирование).
- ◇ Для получения грубой оценки стоимости частоты выполнения используется *простая эвристика*:
делается допущение, что каждый цикл выполняется 10 раз; тогда стоимость каждой загрузки внутри одного цикла оценивается как 10, внутри гнезда из двух циклов – как 100 и т.д.; стоимость каждой ветви непредсказуемого **if-then-else** оценивается как 0.5.
На практике из этой эвристики, в частности, следует, что сброс выгоднее выполнять в более внешнем цикле.
- ◇ Аннотации могут вычисляться заранее (и тогда потребуются дополнительный просмотр программы), либо во время первого обращения

13.3 Глобальное распределение и назначение регистров


13.3.5 Конфликтные ситуации и граф конфликтов

- ◇ При распределении регистров моделируется состязание за место на регистрах целевой машины.
Рассмотрим два различных интервала жизни LR_i и LR_j . Если в программе существуют команды, во время которых и LR_i , и LR_j актуальны, то они не могут занимать один и тот же регистр. В таком случае говорят, что LR_i и LR_j находятся в конфликте.
- ◇ **Определение.** Интервалы жизни LR_i и LR_j *находятся в конфликте* если один из них актуален при определении другого и они имеют различные значения.
- ◇ Граф, узлы которого соответствуют отдельным интервалам жизни, а дуги соединяют интервалы жизни, находящиеся в конфликте, называется *графом конфликтов* (ГК). Этот граф не является направленным, так как отношение нахождения в конфликте симметрично.
- ◇ Таким образом, если два узла ГК являются смежными (соединены дугой), то им должны соответствовать различные регистры.

13.3 Глобальное распределение и назначение регистров


13.3.6 Раскраска графа

- ◇ Раскраска произвольного графа G состоит в присвоении каждому узлу G определенного цвета таким образом, чтобы любым двум смежным узлам G не были сопоставлены одинаковые цвета.
- ◇ Раскраска, использующая n цветов называется n -раскраской, а наименьшее из таких n называется *хроматическим числом* графа.
На рисунке внизу хроматическое число левого графа равно 2, а правого графа – 3.
- ◇ Проблема нахождения хроматического числа графа и проблема выяснения, допускает ли граф n -раскраску NP -полны.



13.3 Глобальное распределение и назначение регистров

13.3.7 Раскраска графа конфликтов




Фрагмент кода с именами интервалов жизни

◇

Если у целевого компьютера n регистров, то проблема их распределения для программы сводится к проблеме построения n -раскраски ГК

◇

В частности, для данного примера ГК допускает 2-раскраску, следовательно, достаточно 2 регистров





Граф конфликтов

13.3 Глобальное распределение и назначение регистров

13.3.7 Раскраска графа конфликтов

Если оптимизирующая фаза компилятора переставила две последние команды блока B_1 Тогда LR_b будет живым при определении LR_d , и значит в ГК необходимо добавить дугу (LR_b, LR_d) в результате чего ГК уже не будет допускать 2-раскраску, так как $(LR_a, LR_b$ и LR_d должны быть разного цвета)



Теперь у распределителя регистров две возможности:

- 1: Использовать третий регистр
- 2: Перед определением регистра для LR_d сбросить LR_a или LR_b

Фрагмент кода с именами интервалов жизни

Граф конфликтов

13.3 Глобальное распределение и назначение регистров

13.3.8 Построение графа конфликтов

- ◇ После построения глобальных интервалов жизни и множеств *LiveOut* для каждого базового блока можно за один просмотр программы от *Exit* к *Entry* построить ГК.
- ◇ Внутри каждого базового блока алгоритм поддерживает множество *LiveNow* переменных, живых в текущей точке блока. При входе в блок *B* полагают $LiveNow = LiveOut(B)$. Затем просматривают каждую команду блока (*op* LR_a, LR_b, LR_c) и узел ГК, соответствующий переменной LR_a , определяемой в этой команде, соединяют дугами со всеми узлами, соответствующими переменным из *LiveNow* (это как раз переменные, живые во время определения другой переменной).
- ◇ Для повышения эффективности ГК задается левой (нижней) половиной своей матрицы смежности.
- ◇ Операции копирования $\mathbf{LR}_i \leftarrow \mathbf{LR}_j$ не порождают конкуренции между LR_i и LR_j , так как эти значения могут занимать один и тот же регистр.

13.3 Глобальное распределение и назначение регистров

13.3.8 Построение графа конфликтов

◇ Более точно алгоритм можно выразить следующим образом:

```
for each  $LR_i$  do
    create a node  $n_i \in N$ ;
for each basic block  $b$  do{
    LiveNow = LiveOut( $b$ )
    for  $I_n, I_{n-1}, \dots, I_1$  in  $b$  do{
        ||  $I_k$  имеет вид  $op_k LR_a, LR_b, LR_c$ 
        for each  $LR_i \in \text{LiveNow}$ {
            add  $(LR_a, LR_i)$  to  $E$ 
            remove  $LR_a$  from LiveNow
            add  $LR_b$  to LiveNow
            add  $LR_c$  to LiveNow
        }
    }
}
```

13.3 Глобальное распределение и назначение регистров

13.3.9 Слияние интервалов жизни

- ◇ Рассмотрим команду копирования $LR_i = LR_j$. Если ИЖ LR_i и LR_j не находятся в конфликте (не являются смежными узлами ГК), то команду можно исключить и все ссылки на LR_j заменить ссылками на LR_i . В результате ИЖ LR_i и LR_j как бы *сольются*.
- ◇ *Слияние* ИЖ приносит следующие выгоды:
 - ◇ Исключается команда копирования (код становится меньше и тем самым потенциально быстрее)
 - ◇ Снижается степень каждого узла (ИЖ), который был в конфликте либо с LR_i , либо с LR_j .
 - ◇ Множество ИЖ сокращается (в литературе приводится пример, когда в результате слияния ИЖ удалось исключить свыше 30% всех ИЖ).

13.3 Глобальное распределение и назначение регистров

13.3.9 Слияние интервалов жизни

◇ **Пример.** Рассмотрим фрагмент программы:

ADD	LR_a , LR _t , LR _u	a
.....		
LD	LR_b , LR _a	b
LD	LR_c , LR_a	c
.....		
ADD	LR _x , LR_b , LR _w	
ADD	LR _z , LR_c , LR _y	

Отрезки справа от кода отмечают ИЖ **LR_a** **LR_b** **LR_c**
(красным показано определение переменной, зеленым – ее последнее использование).

Несмотря на то, что ИЖ **LR_a** пересекается и с **LR_b**, и с **LR_c**, он не находится в конфликте ни с тем, ни с другим, так как источник и приёмник соответствующих команд копирования не находятся в конфликте.

LR_b и **LR_c** находятся в конфликте, так как **LR_b** жив при определении **LR_c**
ИЖ из обеих операций копирования являются кандидатами на слияние.

13.3 Глобальное распределение и назначение регистров

13.3.9 Слияние интервалов жизни

◇ После слияния LR_a и LR_b :

ADD	LR_{ab}	LR_t	LR_u	ab
.....				
LD	LR_c	LR_{ab}		c
.....				
ADD	LR_x	LR_{ab}	LR_w	
ADD	LR_z	LR_c	LR_y	

◇ После слияния ИЖ LR_a и LR_b получаем новый ИЖ LR_{ab} .

◇ Теперь ИЖ LR_c получается из LR_{ab} командой копирования, и следовательно LR_c и LR_{ab} не находятся в конфликте, так что слияние LR_a и LR_b в LR_{ab} понизило степень LR_c .
Слияние ИЖ может или уменьшить степени смежных узлов (ИЖ), или оставить их без изменения.

◇ Команда копирования $LD\ LR_c, LR_{ab}$ позволяет продолжить процесс слияния ИЖ, заменив LR_{ab} на LR_{abc} .

13.3 Глобальное распределение и назначение регистров

13.3.10 Эвристики раскраски графа конфликтов

- ◇ После того как ГК построен, необходимо решить две задачи:
 - ◇ Для построенного ГК необходимо найти n -раскраску (n – число регистров целевой машины)
 - ◇ Необходимо разработать алгоритм обработки ситуации, когда при необходимости раскраски очередного интервала жизни (узла ГК) выясняется, что все n цветов исчерпаны
- ◇ Поскольку проблема n -раскраски графа NP -полна, применяются быстрые эвристические алгоритмы. При этом нет гарантии, что n -раскраска будет построена
- ◇ При исчерпании регистров применяются либо *слив*, либо *расщепление* ИЖ (узлов ГК).
В обоих случаях исходный ГК преобразуется к новому ГК, который может допускать n -раскраску.

13.3 Глобальное распределение и назначение регистров

13.3.10 Алгоритм раскраски графа конфликтов

- ◇ **1 фаза. Установление порядка рассмотрения узлов**
узлы по очереди удаляются из ГК и помещаются в стек.
- ◇ Узел ГК называется неограниченным, если его степень $< n$, и ограниченным, если его степень $\geq n$.
- ◇ Сначала в произвольном порядке удаляются неограниченные узлы вместе с дугами, соединяющими их со смежными узлами, при этом степень части смежных узлов понижается, так что некоторые из ограниченных узлов после удаления могут стать неограниченными.
- ◇ Если после удаления всех неограниченных узлов в ГК все еще остаются узлы, то все они ограничены. Для каждого из ограниченных узлов вычисляется их степень (количество смежных узлов).
- ◇ Ограниченные узлы удаляются из графа и помещаются в стек в порядке возрастания степени.

В конце фазы граф конфликтов пуст, а все его узлы (ИЖ) находятся в стеке в некотором порядке.

13.3 Глобальное распределение и назначение регистров

13.3.10 Алгоритм раскраски графа конфликтов

◇ 2 фаза. Раскраска узлов

распределитель восстанавливает ГК, выбирая из стека очередной узел l и раскрашивая его в цвет, отличный от цвета смежных узлов. Если оказывается, что все цвета использованы, узел l остается нераскрашенным.

В конце фазы стек пуст, а ГК восстановлен и часть его узлов раскрашена.

13.3 Глобальное распределение и назначение регистров

13.3.10 Алгоритм раскраски графа конфликтов



3 фаза. Проверка на окончание процесса раскраски

Если нераскрашенных узлов не осталось, алгоритм завершается. Если часть узлов ГК осталась нераскрашенной, то для каждого такого узла либо генерируются команды сброса (*слив*), либо интервал жизни, соответствующий узлу *расщепляется* (на два или более подинтервалов), после чего ГК перестраивается с учетом слива и/или разделенных узлов. После перестройки ГК делается переход на первую фазу.




Ключевым моментом является порядок в котором узлы ГК помещаются в стек.

Наиболее распространенный эвристический критерий слива узла – минимум отношения

$$\frac{\text{цена_сброса}}{\text{степень_узла}}$$

13.3 Глобальное распределение и назначение регистров

13.3.11 Структура распределителя регистров



- ◆ Найти ИЖ всех переменных, построить ГК, вычислить стоимость сброса для каждого ИЖ, выполнить раскраску ГК. После этого либо каждый ИЖ получит цвет (**положительный исход**), либо часть ИЖ останутся неокрашенными (**отрицательный исход**).
- ◆ В случае положительного исхода каждому ИЖ присваивается физический регистр.
- ◆ В случае отрицательного исхода ГК перестраивается и снова выполняется раскраска ГК.

13.3 Глобальное распределение и назначение регистров

13.3.12 Перестройка графа конфликтов

- ◇ Перестройка ГК достигается помимо слияния ИЖ (п. 13.3.9) с помощью *сливания* переменных (п. 13.3.13) и *расщепления* ИЖ (п.13.3.14).







13.3 Глобальное распределение и назначение регистров

13.3.13 Сливание переменных

- ◇ *Сливание* временной переменной **t** состоит в следующем:
 - ◇ в «автоматической» памяти процедуры выделить ячейку **ta** для хранения значений **t** (эту ячейку называют «дом» **t**);
 - ◇ перед каждой командой, использующей **t**, вставить команду **LD t, ta**;
 - ◇ после каждой команды, определяющей **t**, вставить команду **ST ta, t**;
 - ◇ просматривают текст полученной процедуры с целью выявить и удалить лишние команды **LD** и **ST** (иногда это удается).

13.3 Глобальное распределение и назначение регистров

13.3.13 Сливание переменных



13.3 Глобальное распределение и назначение регистров

13.3.14 Расщепление интервалов жизни

```
ADD a, m, 1
ADD b, k, 4
```

```
ADD a, m, 1
ST  mem, a
ADD b, k, 4
```

◇ На левом рисунке LR_a и LR_b полностью пересекаются. Расщепив LR_a на два LR , удастся устранить конфликт.

```
ADD r, b, m
```

```
ADD r, b, m
```

◇ При этом команды **ST** и **LD** применяются только здесь, а не перед всеми **a**.

```
LD  a, mem
```

```
ADD a, m, 1
```

```
ADD a, m, 1
```


a и b в конфликте

Конфликт между
a и b устранен

13.3 Глобальное распределение и назначение регистров


13.3.15 Примеры глобального распределения регистров

1) Распределение виртуальных (символических) регистров



13.3 Глобальное распределение и назначение регистров

Применим слияние интервалов к команде копирования `s4 = s1` (в блоке `B1`). Получим



Оценим стоимости сброса для оставшихся символических регистров `s1`, `s2`, `s3`, `s5` и `s6`

Символич. регистр	Стоимость сброса			
	<i>B</i> ₁	<i>B</i> ₂	<i>B</i> ₃	<i>B</i> ₄
s1	2.0			
s2	1.0	21.0	2.0	2.0
s3	6.0	20.0	4.0	2.0
s5	2.0		4.0	2.0
s6				∞

Стоимость сброса вычисляется по формуле

$$Spill_cost = DefWt \cdot \sum_{def \in LR} 10^{Depth(def)} + UseWt \cdot \sum_{use \in LR} 10^{Depth(use)} - CopyWt \cdot \sum_{copy \in LR} 10^{Depth(copy)}$$


где *def*, *use* и *copy* – отдельные команды определения, использования и копирования в *LR*, а *DefWt*, *UseWt* и *CopyWt* – стоимости соответствующих команд
При вычислении стоимости сброса считается *DefWt* = *UseWt* = 2.0, *CopyWt* = 1.0
Стоимость *s6* = ∞, так как регистр *s6* – не является живым

13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

2) Построение графа конфликтов

($s_1, \dots, s_6$ – виртуальные регистры, $R_1, \dots, R_5$ – физические регистры)



- ◇ Все физические регистры считаются всегда живыми
- ◇ Пусть частота выполнения блоков B_1, B_3 и B_4 равна 1, а частота выполнения блока B_2 равна 7
- ◇ Каждому символическому регистру соответствует один интервал жизни, поэтому, например, LR_a и s_1 – синонимы
- ◇ На символических регистрах s_1, s_2, s_3, s_4 хранятся значения, поэтому результаты всех вычислений в блоках B_2 и B_3 будем помещать на R_5

13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров


Матрица смежности графа конфликтов имеет вид

	<i>R1</i>	<i>R2</i>	<i>R3</i>	<i>R4</i>	<i>R5</i>	<i>s1</i>	<i>s2</i>	<i>s3</i>	<i>s4</i>	<i>s5</i>
<i>R2</i>	1									
<i>R3</i>	1	1								
<i>R4</i>	1	1	1							
<i>R5</i>	1	1	1	1						
<i>s1</i>	0	0	0	0	1					
<i>s2</i>	0	0	0	0	1	1				
<i>s3</i>	0	0	0	0	1	1	1			
<i>s4</i>	0	0	0	0	1	1	1	1		
<i>s5</i>	0	0	0	0	0	1	1	1	1	
<i>s6</i>	0	0	0	0	1	1	1	1	1	1

13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

Граф конфликтов и его матрица смежности примут вид




	R1	R2	R3	R4	R5	s1	s2	s3	s5
R2	1								
R3	1	1							
R4	1	1	1						
R5	1	1	1	1					
s1	0	0	0	0	1				
s2	0	0	0	0	1	1			
s3	0	0	0	0	1	1	1		
s5	0	0	0	0	1	1	1	1	
s6	0	0	0	0	0	1	1	1	1



13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

Поскольку каждый из узлов R1, R2, R3, R4 имеет меньше пяти смежных узлов, заталкиваем их в стек (порядок произвольный) и удаляем из графа конфликтов. Получается граф, изображенный на правом рисунке



Граф конфликтов до исключения узлов R1, R2, R3, R4




Граф конфликтов после исключения узлов R1, R2, R3, R4



13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

Теперь узел R5 имеет меньше пяти смежных узлов; заталкиваем и его в стек и удаляем из графа конфликтов. Получается граф, изображенный на правом рисунке



Граф конфликтов
до исключения узла R5





Граф конфликтов
после исключения узла R5

13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

Теперь все оставшиеся узлы графа конфликтов имеют меньше пяти смежных узлов; заталкиваем их (в произвольном порядке) в стек и удаляем из графа конфликтов.



СТЕК


13.3 Глобальное распределение и назначение регистров

13.3.15 Примеры глобального распределения регистров

Вытаскиваем регистры из стека и присваиваем каждому свободный цвет (всего имеется пять цветов). R5 имеет 4 смежных узла: s1(1), s2(2), s3(3) и s6(5). Следовательно, ему можно присвоить цвет 4 (только он свободен).

	Регистр	Цвет
s1	s1	1
s2	s2	2
s3	s3	3
s5	s5	4
s6	s6	5
R5	R5	4
R4	R4	1
R3	R3	2
R2	R2	3
R1	R1	5

Стек



13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

- ◇ Пусть доступно R регистров и пусть составлен список из n интервалов жизни. Алгоритм Linear scan должен распределить на регистры как можно больше ИЖ таким образом, чтобы никакие пересекающиеся ИЖ не были распределены на один и тот же регистр.
- ◇ Если $n > R$ и ИЖ пересекаются в некоторой точке, то по крайней мере $n - R$ ИЖ должны быть размещены в памяти.
- ◇ Количество пересекающихся ИЖ изменяется только в начале и в конце одного из ИЖ.
- ◇ Все ИЖ помещаются в список, отсортированный по возрастанию их начал. Тогда алгоритм может быстро просмотреть все ИЖ, перескакивая с одного начала ИЖ к следующему. На каждом шагу алгоритм поддерживает список активных ИЖ, которые пересекаются в данной точке и уже размещены на регистрах. Этот список активных поддерживается отсортированным по возрастанию концов входящих в него ИЖ.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)



На псевдокоде

```
active ← {}
```

```
for each live interval i в порядке  
возрастания начал
```

```
    ExpireOldIntervals(i) //окончание  
                               старых интервалов
```

```
if length(active) = R then
```

```
    SpillAtInterval(i) //слив интервала i
```

```
else
```

```
    register[i] ← регистр, удаляемый из  
                    пула свободных регистров
```

```
    добавить i в active, отсортированный  
    по возрастанию концов ИЖ
```

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

◇ На псевдокоде

```
ExpireOldIntervals(i)
```

```
foreach interval j in active, in order of  
increasing end point
```

```
if endpoint[j]  $\geq$  startpoint[i] then
```

```
    remove j from active
```

```
    add register[j] to pool of free  
    registers
```

```
return
```

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)



На псевдокоде

SpillAtInterval(i)

spill $\leftarrow$ last interval in active

if endpoint[spill] > end point[i] **then**

register[i] $\leftarrow$ **register**[spill]

location[spill] $\leftarrow$ new stack location

remove spill from active

add i to active, sorted by increasing
 end point

else

location[i] $\leftarrow$ new stack location

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)


- ◇ При обнаружении каждого нового ИЖ алгоритм просматривает список **active** с начала до конца. Во время просмотра из списка удаляются все закончившиеся ИЖ (ИЖ, которые больше не пересекаются, так как конец одного из них раньше начала другого) и делает соответствующий регистр доступным для распределения.



13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

◇ Пример. Пусть доступно всего два регистра **r1** и **r2**.



◇ ИЖ обрабатываются в порядке **v1**, **v2**, **v3**, **v4**, **v5**.


Сначала список **Active** пуст.

На первом шаге обрабатывается ИЖ **v1**. Так как список **Active** пуст, регистр **r1** выделяется для **v1**, и **v1** заносится в список **Active**.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

◇ Пример. Пусть доступно всего два регистра **r1** и **r2**.




◇ ИЖ обрабатываются в порядке **v1**, **v2**, **v3**, **v4**, **v5**.
После первого шага список **Active** содержит ИЖ **v1**.
На втором шаге обрабатывается ИЖ **v2**. Так как **v1** продолжает оставаться активным, **v1** не исключается из списка **Active**, и для ИЖ **v2** выделяется единственный свободный регистр **r2**, а **v2** заносится в список **Active**.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

◇ Пример. Пусть доступно всего два регистра r1 и r2.



Текущий шаг

◇ На рисунках показано состояние до и после третьего шага.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

◇ Пример. Пусть доступно всего два регистра $r1$ и $r2$.

(1) $v1 = 10$	(1) $m1 = 10$
(2) $v2 = 20$	(2) $r2 = 20$
(3) $v3 = v1 + v2$	(3) $r1 = m1 + r2$
(4) $v4 = v2 + v3$	(4) $r2 = r2 + r1$
(5) $v1 = v3 + v4$	(5) $m1 = r1 + r2$
(6) $v5 = v4 + v1$	(6) $r1 = r2 + m1$
(7) return ($v1 + v5$)	(7) return ($m1 + r1$)

◇ Полученное распределение регистров показано на рисунке. Метод раскраски графа конфликтов обеспечивает для рассмотренного примера лучшее распределение регистров.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

- ◇ **Пример.** Пусть доступно всего два регистра $r1$ и $r2$.
- ◇ Метод раскраски графа конфликтов обеспечивает для рассмотренного примера лучшее распределение регистров.

(1) $v1 = 10$	(1) $r2 = 10$
(2) $v2 = 20$	(2) $r1 = 20$
(3) $v3 = v1 + v2$	(3) $r2 = r2 + r1$
(4) $v4 = v2 + v3$	(4) $r1 = r1 + r2$
(5) $v1 = v3 + v4$	(5) $r2 = r2 + r1$
(6) $v5 = v4 + v1$	(6) $r1 = r1 + r2$
(7) return ($v1 + v5$)	(7) return ($r2 + r1$)

- ◇ Но метод раскраски графа конфликтов имеет асимптотическую временную сложность $O(n^2)$.
Метод линейного сканирования реализует распределение регистров за один просмотр текста программы и имеет асимптотическую временную сложность $O(n)$.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

- ◇ В отличие от метода раскраски графа конфликтов, имеющего асимптотическую временную сложность $O(n^2)$, метод линейного сканирования реализует распределение регистров всего за один просмотр текста программы и имеет асимптотическую временную сложность $O(n)$.
- ◇ Разработчики JIT-компиляторов (например, для языка *Java* или для языка *Python*) предпочитают метод линейного сканирования.
- ◇ В последнее время используется модификация метода линейного сканирования, называемая *Second Chance Binpacking*. Во многих случаях она позволяет увеличить точность линейного сканирования, сохраняя асимптотическую временную сложность $O(n)$.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – метод линейного сканирования (Linear scan)

- ◇ В отличие от метода раскраски графа конфликтов, имеющего асимптотическую временную сложность $O(n^2)$, метод линейного сканирования реализует распределение регистров всего за один просмотр текста программы и имеет асимптотическую временную сложность $O(n)$.
- ◇ Разработчики JIT-компиляторов (например, для языка *Java* или для языка *Python*) предпочитают метод линейного сканирования.
- ◇ В последнее время используется модификация метода линейного сканирования, называемая *Second Chance Binpacking*. Во многих случаях она позволяет увеличить точность линейного сканирования, сохраняя асимптотическую временную сложность $O(n)$. Рассмотрим кратко этот метод.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – модифицированный метод линейного сканирования (Second Chance Binpacking)

- ◇ Одним из основных недостатков метода линейного сканирования является тот факт, что он не рассматривает возможных «дыр» в ИЖ.
В то же время анализ ГПУ реальных программ показывает, что такие дыры нередко возникают в связи с многочисленными ветвлениями. Даже простой пример, рассмотренный выше, подтверждает это.
- ◇ В самом деле ИЖ для $v1$ имеет дыру от инструкции (3) до инструкции (5): значение $v1 == 10$ после инструкции (3) не используется, а в инструкции (5) переопределяется.

```
(1) v1 = 10
(2) v2 = 20
(3) v3 = v1 + v2
(4) v4 = v2 + v3
(5) v1 = v3 + v4
(6) v5 = v4 + v1
(7) return (v1 + v5)
```

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – модифицированный метод линейного сканирования (Second Chance Binpacking)



В самом деле ИЖ для $v1$ имеет дыру от инструкции (3) до инструкции (5): значение $v1 == 10$ после инструкции (3) не используется, а в инструкции (5) вообще переопределяется.

Методу линейного сканирования, который игнорирует этот факт, приходится и после инструкции (3) хранить в памяти (так как регистров не хватает) мертвое значение $v1$.



В модифицированном методе реализована возможность расщепления ИЖ.

Эта возможность позволяет расщепить ИЖ $v1$ на два ИЖ – $v11$ и $v12$. В итоге $v1$ получает второй шанс занять регистр.

Отметим, что если бы использовалась SSA-форма, расщепления бы не потребовалось, оно бы произошло автоматически.

(1) $v1 = 10$

(2) $v2 = 20$

(3) $v3 = v1 + v2$

(4) $v4 = v2 + v3$


(5) $v1 = v3 + v4$

(6) $v5 = v4 + v1$

(7) **return** ($v1 + v5$)

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – модифицированный метод линейного сканирования (Second Chance Binpacking)



◇ В модифицированном алгоритме ИЖ **v1** сначала помещается в список **Active**, на третьем шаге переводится в список **Inactive**, а на пятом шаге снова помещается в список **Active**. В итоге получается распределение регистров, показанное на рисунке.

13.3 Глобальное распределение и назначение регистров

13.3.11 Быстрый алгоритм распределения регистров – модифицированный метод линейного сканирования (Second Chance Binpacking)

- ◇ Модифицированный алгоритм имеет **примерно** такую же скорость, как и базовый алгоритм линейного сканирования, и при этом генерирует код **примерно** такого же качества, что и алгоритм раскраски графа конфликтов.