

Московский физико-технический институт
(государственный университет)
Физтех-школа радиотехники и компьютерных технологий
Кафедра информатики и вычислительной техники

Доработка статического анализа кода для выявления потенциальных ошибок в программах

Выпускная квалификационная работа
(бакалаврская работа)

Выполнил: Левченко Д.Н., 713 группа

Научный руководитель: к.т.н. Ермолицкий А.В.

Введение: анализ кода

Статический и динамический анализ

	Статический анализ	Динамический анализ
Преимущества	<ul style="list-style-type: none">• Используется на ранних этапах разработки;• Позволяет анализировать существующую базу кода без компиляции;• Интегрируется в среду разработки.	<ul style="list-style-type: none">• Высокая продуктивность по нахождению ошибок;• Для отслеживания причины ошибки может быть произведена полная трассировка стека и среды исполнения.
Недостатки	<ul style="list-style-type: none">• Большая вероятность ложно-положительных срабатываний.	<ul style="list-style-type: none">• Вмешательства в работу программы;• Полнота анализа ошибок зависит от степени покрытия кода.

Введение: инструменты статического анализа

	Статические анализаторы	Компиляторы
Преимущества	<ul style="list-style-type: none">• Выявляют больше ошибок в программах.	<ul style="list-style-type: none">• Простота использования;• Низкая стоимость нахождения ошибки.
Недостатки	<ul style="list-style-type: none">• Требуют отдельной настройки;• Требуют много памяти и времени;• Хороший анализатор – коммерческий продукт с высокой стоимостью.	<ul style="list-style-type: none">• Необходим баланс между временем работы и полнотой анализа. Зачастую последняя страдает.

Цель работы

Цель работы:

Разработать модуль в языковом компиляторе LCC, осуществляющий статический анализ с выдачей пользовательских предупреждений, для выявления потенциальных ошибок в программах для языков C и C++.

Задачи:

1. Разработать модуль в языковом компиляторе LCC, осуществляющий статический анализ с выдачей предупреждений по запросу пользователей:
 - a) о неиспользуемых переменных;
 - b) об использовании переменных в охватываемой области видимости;
 - c) об использовании неинициализированных полей структур.
2. Отладить анализ на коротких направленных тестах, самосборке языкового компилятора и задачах SPEC CPU (95, 2000, 2006, 2017) для языков C и C++.
3. Собрать статистику по эффективности данного анализа для выявления потенциальных ошибок в целевых программах.

Задача 1а: анализ неиспользуемых переменных

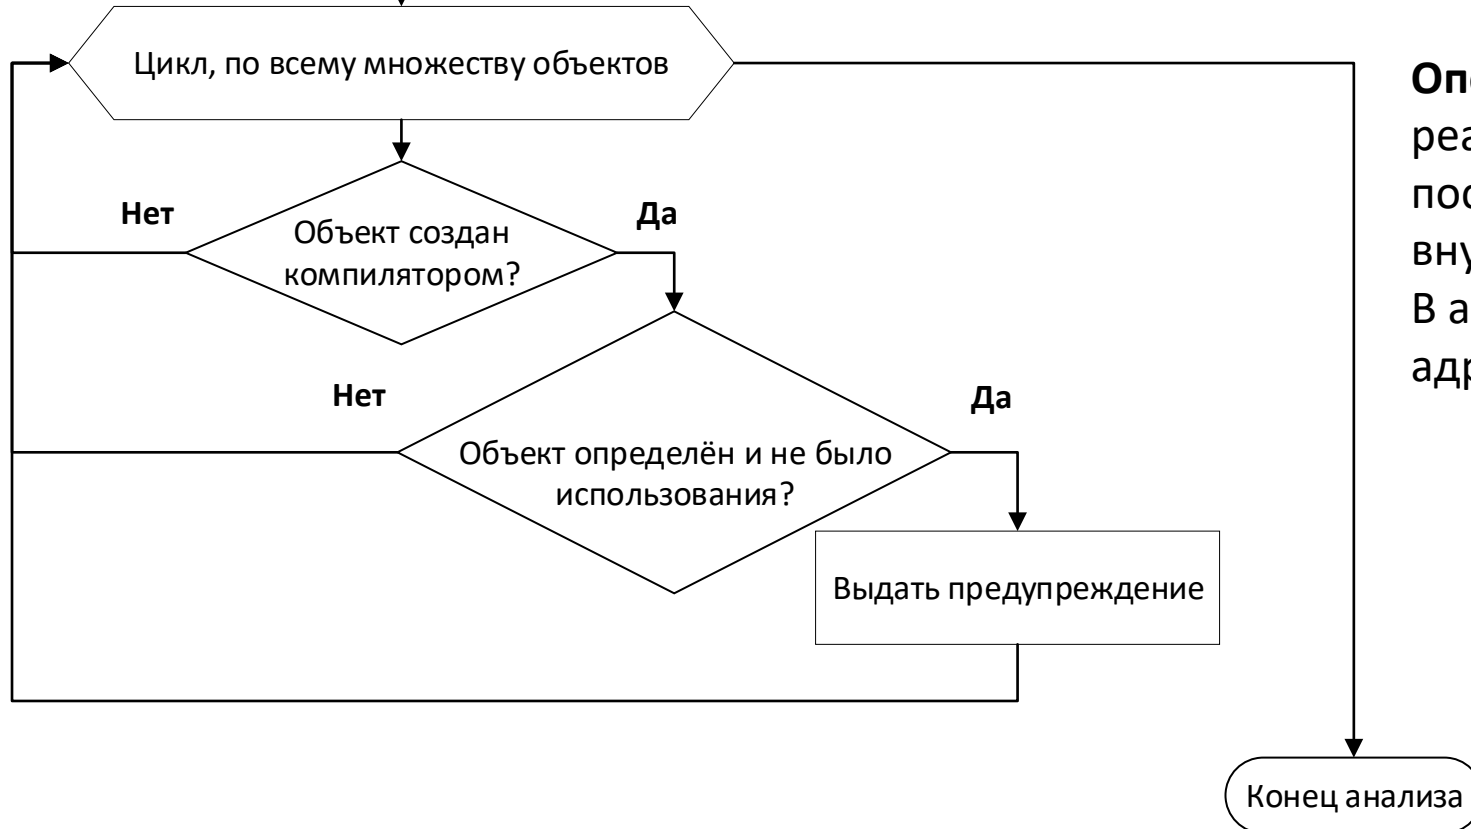
Пример неиспользуемой переменной

```
1 double foo( double x1, double x2)
2 {
3     double a1, a2, b1, b2;
4
5     a1 = sin( x1);           Переменная определена, но не использована
6     a2 = cos( x2); <-----
7
8     b1 = bar( a1);          Здесь программист забыл изменить переменную
9     b2 = bar( a1); <-----
10
11     return b1 * b2;
12 }
13 -----
14 Выданное компилятором предупреждение:
15 lcc: "/home/levchenko_d/test.c", line 2: in function "foo":
16 lcc: "/home/levchenko_d/test.c", line 3: warning: variable "a2" is set, but not
17 | | | | | used [-Wunused-but-set-variable]
```

Задача 1а: алгоритм поиска неиспользуемых переменных

Получение функции.
Получение её множеств
автоматических объектов и операций

Каждому объекту по операции определить параметры:
Использование, инициализация, взятие адреса.



Автоматический объект – описание каждой локальной переменной во внутреннем представлении компилятора LCC. Имеет свойства: был ли объект использован, инициализирован, брался ли на него адрес, имя объекта и т.д.

Операция - высокоуровневая абстракция над реальной машинной инструкцией (или последовательным набором инструкций) для внутреннего представления компилятора. В анализе используются операции чтения, записи, адресные операции.

Задача 1а: результаты поиска неиспользуемых переменных

Отладка анализа произведена на:

- Наборе самописных направленных тестов (27 шт.);
- Самосборке языкового компилятора;
- Исходниках бенчмарков SPEC CPU (95, 2000, 2006, 2017) для языков C и C++.

Результаты проведения анализа и сравнение с существующими решениями

Статистика собрана на исходниках бенчмарков
SPEC CPU (95, 2000, 2006, 2017) для языков C и C++

	GCC	Cppcheck	EDG	LCC
Количество предупреждений	941	3583*	1263	1507

*имеет много дублирующих предупреждений, статистика несколько завышена.

Задача 1b: анализ возможного использования переменных в охватывающей области видимости

Адрес локальной переменной нельзя записывать в переменную с охватывающей областью видимости

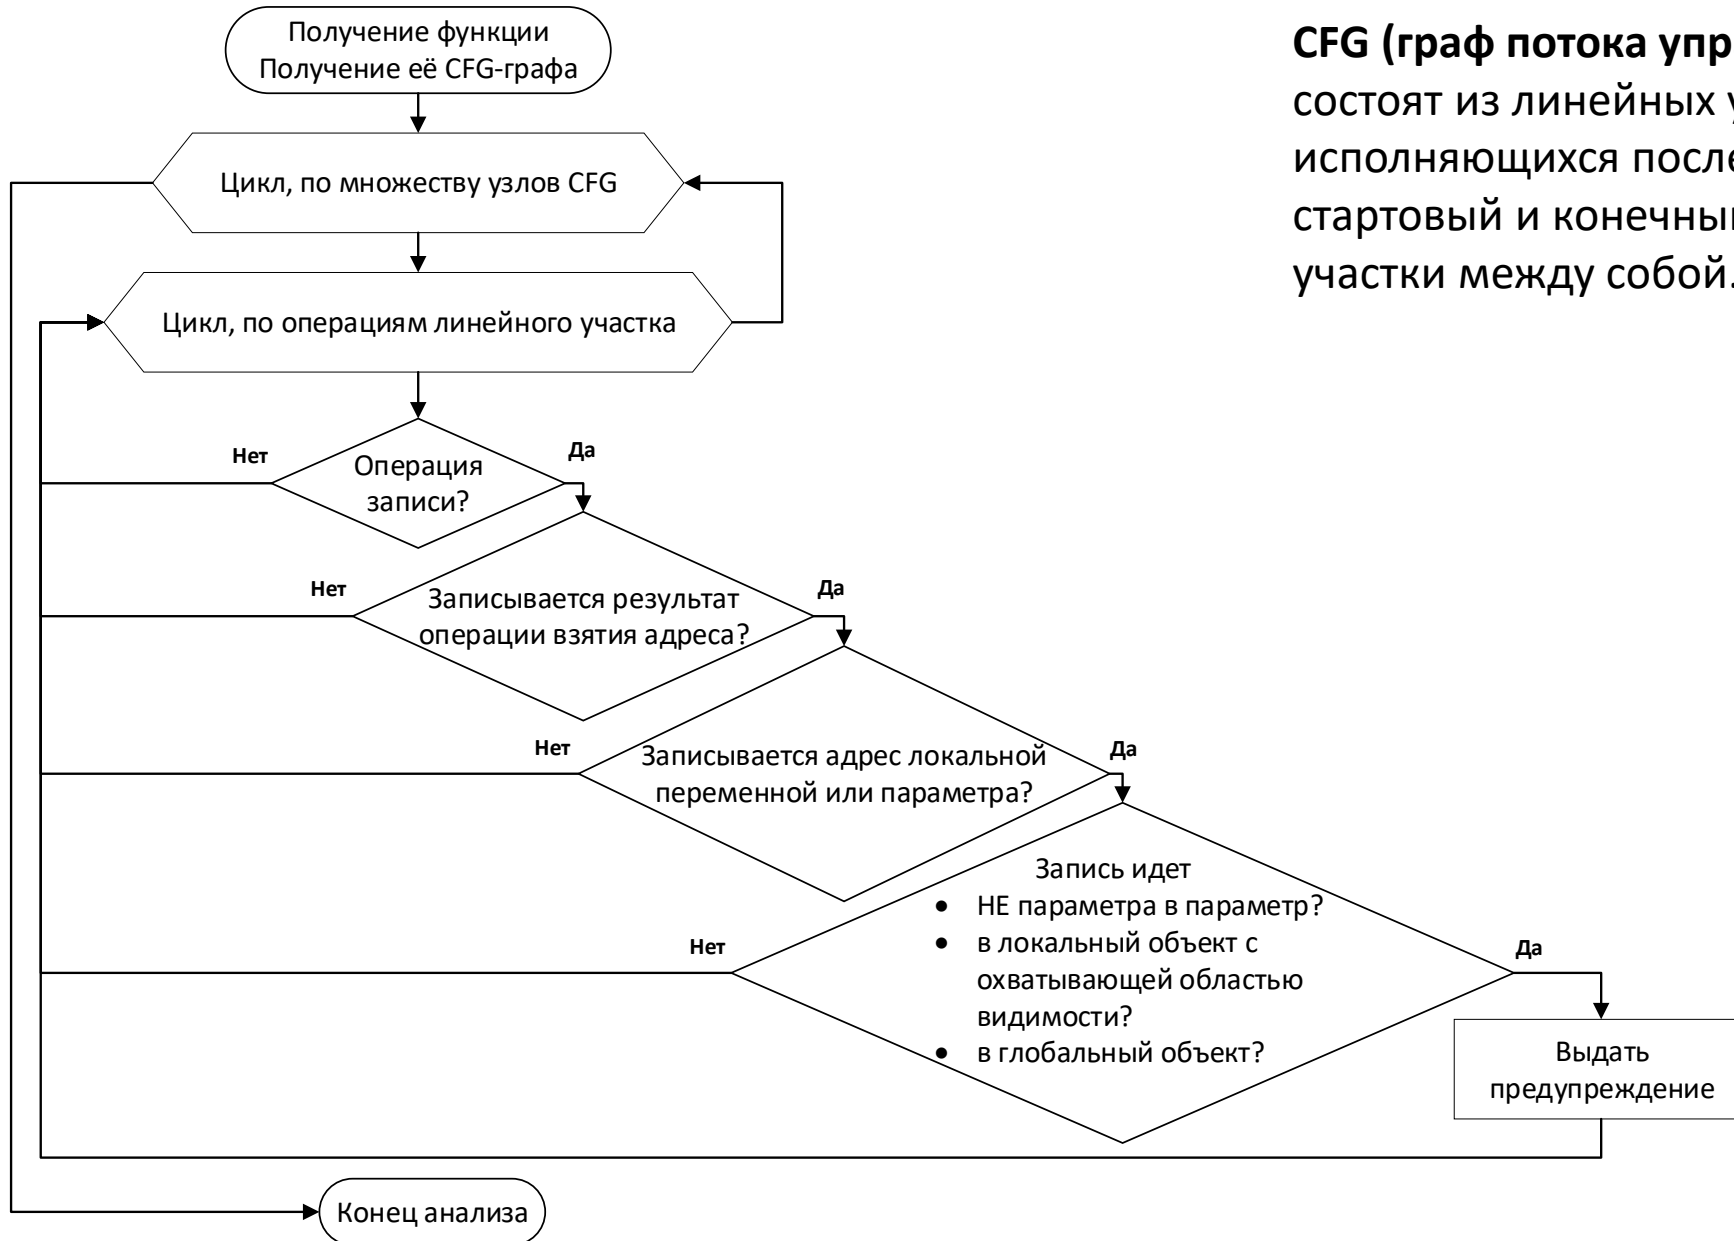
Пример с локальной переменной

```
1 void foo()
2 {
3     int * ptr;
4
5     if(1)
6     {
7         int var;
8         ptr = &var; <----- Запись адреса локальной переменной
9     }                                     в указатель с большим временем жизни
10
11     *ptr = 1; <----- Недопустимое использование
12 }
13 -----
14 Выданное компилятором предупреждение:
15 lcc: "/home/levchenko_d/test.c", line 2: in function "foo":
16 lcc: "/home/levchenko_d/test.c", line 8: warning: address of local variable
17     "var" is written into variable "ptr" with larger scope
18     [-Wmaybe-use-out-of-scope]
```

Пример с глобальной переменной

```
1 int * ptr;
2
3 void foo()
4 {
5     int var;
6     ptr = &var; <----- Запись адреса локальной переменной в глобальный указатель
7 }
8
9 void bar()
10 {
11     foo();
12     *ptr = 1; <----- Недопустимое использование
13 }
14 -----
15 Выданное компилятором предупреждение:
16 lcc: "/home/levchenko_d/test.c", line 4: in function "foo":
17 lcc: "/home/levchenko_d/test.c", line 6: warning: address of local variable
18     "var" is written into global variable "ptr"
19     [-Wmaybe-use-out-of-scope]
```


Задача 1b: алгоритм поиска использования переменных в охватывающей области видимости



CFG (граф потока управления) – граф, узлы которого состоят из линейных участков операций, исполняющихся последовательно. Обязательно содержит стартовый и конечный узел. Рёбра соединяют линейные участки между собой.

Отладка анализа произведена на:

- Наборе самописных направленных тестов (6 шт.);
- Самосборке языкового компилятора;
- Исходниках бенчмарков SPEC CPU (95, 2000, 2006, 2017) для языков C и C++.

Результаты проведения анализа и сравнение с существующими решениями

Статистика собрана на исходниках бенчмарков SPEC CPU (95, 2000, 2006, 2017) для языков C и C++.

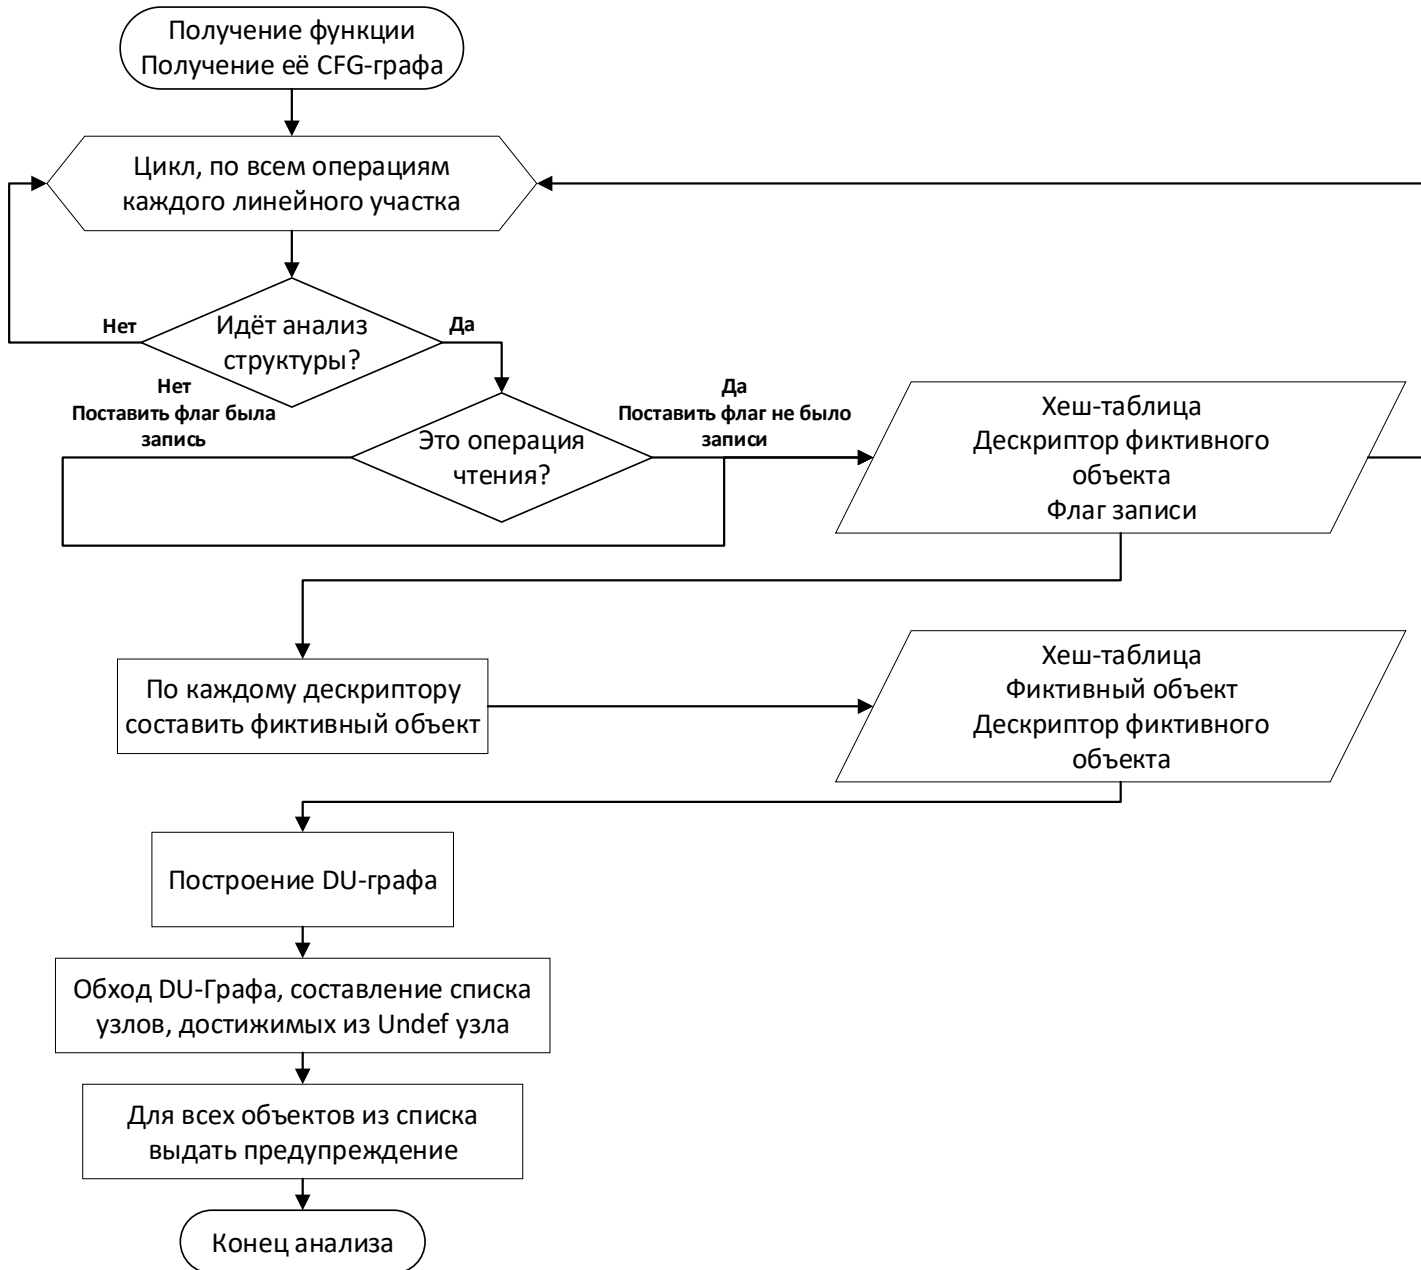
	GCC	Cppcheck	EDG	LCC
Количество предупреждений	-	1	-	96

Задача 1с: анализ неинициализированных полей структур

Пример

```
1  typedef struct point
2  {
3      int x, y;
4  } point;
5
6  void foo( point * p)
7  {
8      point p_temp;
9
10     p_temp.x = 1; <----- Программист забыл инициализировать поле y
11
12     (*p).x = p_temp.x;           А затем прочитал неинициализированное поле
13     (*p).y = p_temp.y; <-----
14 }
15 -----
16 Выданное компилятором предупреждение:
17 lcc: "/home/levchenko_d/test.c", line 7: in function "foo":
18 lcc: "/home/levchenko_d/test.c", line 12: warning: struct field "p_temp.y" is used
19 | | | | uninitialized [-Wuninitialized]
```

Задача 1с: алгоритм поиска неинициализированных полей структур



DU-граф (граф определений и использований) – граф, в узлах которого идет либо определение объекта, либо его использование. В местах схождения потоков данных строятся phi-узлы.

Phi-узел - это инструкция, используемая для выбора значения в зависимости от того, откуда пришли данные на вход.

Undef узел – phi узел, соответствующий неопределённому значению.

Фиктивный объект – объект, который временно строится для каждого поля структуры для дальнейшего дополнения DU-графа.

Задача 1с: результаты поиска неинициализированных полей структур

Отладка анализа произведена на:

- Наборе самописных направленных тестов (14 шт.);
- Самосборке языкового компилятора;
- Исходниках бенчмарков SPEC CPU (95, 2000, 2006, 2017) для языков Си С++.

Результаты проведения анализа и сравнение с существующими решениями

Статистика собрана на исходниках бенчмарков
SPEC CPU (95, 2000, 2006, 2017) для языков С и С++

	GCC	Cppcheck	EDG	LCC
Количество предупреждений	30	-	-	47

Результаты

1. Реализован модуль в составе компилятора LCC для статического анализа программ с выдачей пользовательских предупреждений:
 - о неиспользуемых переменных;
 - об использовании переменных в охватывающей области видимости;
 - об использовании неинициализированных полей структур.
2. Анализ был отлажен на коротких направленных тестах, самосборке языкового компилятора и задачах SPEC CPU (95, 2000, 2006, 2017) для языков C и C++.
3. Статистика эффективности анализа собрана на задачах SPEC CPU (95, 2000, 2006, 2017) для языков C и C++ . Продемонстрирован прирост найденных ошибок по сравнению с фронтендом EDG.

Приложение

Найденные неиспользуемые переменные,
которые не нашли другие компиляторы

523.xalancbmk_r: TraverseSchema.cpp: 5359

```
1  if (!typeInfo)
2  {
3      if (!XMLString::equals(typeURI, SchemaSymbols::fgURI_SCHEMAFORSCHEMA) ||
4          XMLString::equals(fTargetNSURIStr, SchemaSymbols::fgURI_SCHEMAFORSCHEMA))
5      {
6
7          DOMELEMENT* typeNode = fSchemaInfo->getTopLevelComponent(SchemaInfo::C_ComplexType,
8                                                                    SchemaSymbols::fgELT_COMPLEXTYPE,
9                                                                    localPart,
10                                                                     &fSchemaInfo);
11
12         if (typeNode)
13         {
14             // fBuffer is reused by traverseComplexTypeDecl, so we have to store its current value
15             XMLBuffer buffCopy(fBuffer.getLen()+1, fMemoryManager);
16             buffCopy.set(fBuffer.getRawBuffer());
17             int typeIndex = traverseComplexTypeDecl(typeNode); <-----
18             typeInfo = fComplexTypeRegistry->get(buffCopy.getRawBuffer());
19         }
20     }
```

Приложение

Найденные возможные использования переменных за область их жизни,
которые не нашли другие компиляторы

177.mesa: eval.c: 2065

```
1 void gl_EvalCoord1f(GLcontext* ctx, GLfloat u)
2 {
3     ...
4     GLubyte *colorptr;
5
6     /** Color **/
7     if (ctx->Eval.Map1Color4) {
8         ...
9     }
10    else {
11        GLubyte col[4];
12        COPY_4V(col, ctx->Current.ByteColor );
13        colorptr = col;
14    }
15    ...
16 }
```

Здесь происходит запись адреса локальной переменной
в переменную с большей областью определения

