C++ линтеры — хорошо, но недостаточно

Евгений Фёклин

C++ developer

Докладчик

Евгений Фёклин

feklin@viva64.com

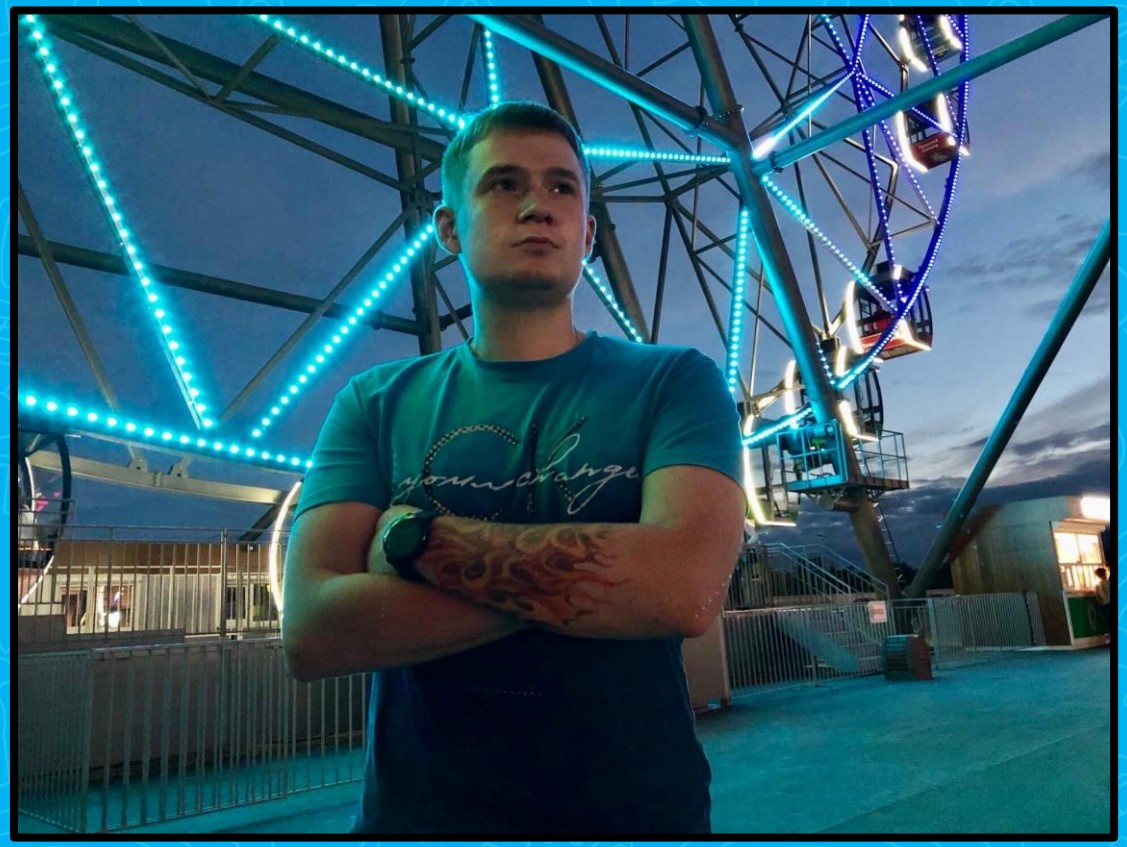

- Разработчик в C++ команде PVS-Studio
- Разработчик игр

Линтеры, или с чего начинался статический анализ кода

Что такое линтеры?

- Линтер – это программа, которая помогает программистам улучшить качество своего кода.
- Проверяет исходный код на соответствие стилевым правилам. Выявляет простые потенциальным ошибки и неэффективные практики.

Запрещённые функции, именования и т.д.

- MISRA C: **exit, system**
- Стили: переменные и функции с большой буквы
- '**strcpy**': This function or variable may be unsafe. Consider using **strcpy_s** instead.

Ошибка в условии

```
int main() {
  int x = 10;
  if (x = 5) {
    std::cout << "x is 5" << std::endl;
  }

  return 0;
}
```

Нет ошибки в условии

```
int main() {
  int x = 10;
  if (x == 5) {
    std::cout << "x is 5" << std::endl;
  }

  return 0;
}
```

Неиспользуемая переменная

```
int main() {
  int x = 10;
  int y = 20;

  std::cout << "x = " << x << std::endl;

  return 0;
}
```

Красота? Вот только чуть сложнее, и ...

- if (a + 1 < a + 1)
- if (a + 1**U** < a + 1**u**) *// Но при этом надо различать A и a*
- if (a + **0x1** < a + **1**)
- if (a + 1 **/*foo*/** < a + 1)
- if (**(**a + 1**)** < a + 1)
- if (**(**a**)** + 1 < a + 1)
- if (a + 1 < a + **((((**1**))))**)

Проблематика подхода в лоб

- Линтеры могут применять жёсткие правила к коду, что может привести к недопониманию его смысла и намерений разработчика.

Способ решения: синтаксическое дерево

- С деревом проще решать подобные задачи
  - Легко пропускать скобки
  - В разном порядке сравнивать
  - Легко понять, что 1u и 1U одно и то же
  - В целом легче делать различные исключения

Ограничения регулярных выражений

- Не раскрываются макросы
- Не раскрываются #include

StarEngine, C++

```
PUGI__FN bool set_value_convert(char_t*& dest, uintptr_t& header,
                                uintptr_t header_mask, int value)
{
  char buf[128];
  sprintf(buf, "%d", value);

  return set_value_buffer(dest, header, header_mask, buf);
}
```

StarEngine, C++

```
#define sfstream std::fstream
#define schar char
#define suchar unsigned schar
#define sprintf std::printf
#define satof atof
#define satoi atoi

PUGI__FN bool set_value_convert(char_t*& dest, uintptr_t& header,
                                uintptr_t header_mask, int value)
{
  char buf[128];
  sprintf(buf, "%d", value);

  return set_value_buffer(dest, header, header_mask, buf);
}
```

PVS-Studio: V614 Uninitialized buffer 'buf' used. pugixml.cpp 3362

Решение: препроцессирование

- Процесс раскрытия в исходном коде директив компилятора и подстановка значений макросов
- Преобразованный код становится более пригодным для анализа и понимания

Важность сбора семантической информации

- Не зная тип *x* и *y* нельзя сказать, есть здесь ошибка или нет

```
unsigned x = ((rectP.right-rectP.left) - width) / 2 +
              rectP.left;
unsigned y = ((rectP.bottom-rectP.top) - height) / 2 +
              rectP.top;
if(x < 0) x = 0;
if(y < 0) y = 0;
```

PVS-Studio: V547 Expression 'y < 0' is always false. Unsigned type value is never < 0. fceux gui.cpp 33

А вот выход за границу массива?

```
float A[10];
for (size_t i = 0; i < sizeof(A); i++)
{
  // Известно, что значение i лежит в пределах [0..39].
  A[i] = 1.0; // Сообщение о выходе за границу массива.
}
```

Добро пожаловать в мир анализа потока данных

- Диапазон
- Множество
- Точное значение
- Указатель на буфер размера N байт
- Нулевой указатель / Ненулевой указатель
- Валидный указатель / Освобождённый указатель
- И т.д.

```
static const int kDaysInMonth[13] = {
  0, 31, 28, 31, 30, 31, 30, 31, 31, 30, 31, 30, 31
};

bool ValidateDateTime(const DateTime& time) {
  if (time.year   < 1 || time.year   > 9999 ||
      time.month  < 1 || time.month  > 12   ||
      time.day    < 1 || time.day    > 31   ||
      time.hour   < 0 || time.hour   > 23   ||
      time.minute < 0 || time.minute > 59   ||
      time.second < 0 || time.second > 59) {
    return false;
  }
  if (time.month == 2 && IsLeapYear(time.year)) {
    return time.month <= kDaysInMonth[time.month] + 1;
  } else {
    return time.month <= kDaysInMonth[time.month];
  }
}
```

Protobuf, C++

```
static const int kDaysInMonth[13] = {
  0, 31, 28, 31, 30, 31, 30, 31, 31, 30, 31, 30, 31
};

bool ValidateDateTime(const DateTime& time) {
  if (time.year   < 1 || time.year   > 9999 ||
      time.month  < 1 || time.month  > 12   ||
      time.day    < 1 || time.day    > 31   ||
      time.hour   < 0 || time.hour   > 23   ||
      time.minute < 0 || time.minute > 59   ||
      time.second < 0 || time.second > 59) {
    return false;
  }
  if (time.month == 2 && IsLeapYear(time.year)) {
    return time.month <= kDaysInMonth[time.month] + 1;
  } else {
    return time.month <= kDaysInMonth[time.month];
  }
}
```

PVS-Studio: V547 / CWE-571 Expression 'time.month <= kDaysInMonth[time.month] + 1' is always true. time.cc 83 (+ аналогичное на проверку ниже)

А если посчитать нельзя?

```
void F(int X)
{
  int A = X;
  int B = X + 10;
  int Q[5];
  Q[B - A] = 1;
}
```

PVS-Studio: V557 CWE-787 Array overrun is possible. The 'B - A' index is pointing beyond array bound. test.cpp 126

Символьное выполнение

```
void F(int A, int B, int C)
{
  if (A < B)
    if (B < C)
      if (A < C)
        foo();
}
```

PVS-Studio: V547 CWE-571 Expression 'A < C' is always true. test.cpp 137

А вот такой код ошибочен или нет?

```
int main(int argc, char **argv)
{
  ....
  QByteArray arg(argv[a]);
  ....
  arg = arg.mid(1);
  arg.toLower();
  if (arg == "o")
    ....
 }
```

QByteArray QByteArray::toLower() **const**

PVS-Studio: V530 The return value of function 'toLower' is required to be utilized. main.cpp 1522

А вот такой код ошибочен или нет?

```
int main(int argc, char **argv)
{
  ....
  QByteArray arg(argv[a]);
  ....
  arg = arg.mid(1);
  arg = arg.toLower();
  if (arg == "o")
    ....
 }
```

PVS-Studio: V530 The return value of function 'toLower' is required to be utilized. main.cpp 1522

Аннотирование функций

```
int foo() {
    return (rand() % 2 == 0) ? 10 : 20;
}

int main(void) {
    int A[15];
    A[foo()] = 1;
}
```

PVS-Studio: V557 Array overrun is possible. The value of 'foo()' index could reach 20.

А теперь соберём всё вместе

- Сопоставление с шаблоном (родственник регулярок)

- Но теперь мы знаем много информации
  - Как работают функции
  - Типы переменных
  - Значения
  - И т.д.

Можно строить сложные диагностики

```
void appDebuger::CopyDump(const char * src, DWORD from,
                          const char * dst) {
  FILE * file = fopen(src, "rb");
  if (file) {
    ...
    if(size > from) {
      FILE * to = fopen(dst, "a+b");
      if(to) {
        char buf[128];
        while (from < size)
        {
          ...
          fread(buf, s, 1, file);
          fwrite(buf, s, 1, file);              // <=
          ...
```

Приключения капитана Блада

PVS-Studio: V1075 The function expects the file to be opened for writing, but it was opened for reading. Debugger.cpp 172

```
void appDebuger::CopyDump(const char * src,
                          DWORD from, const char * dst) {
  FILE * file = fopen(src, "rb");
  if (file) {
    ...
    if(size > from) {
      FILE * to = fopen(dst, "a+b");
      if(to) {
        char buf[128];
        while (from < size)
        {
          ...
          fread(buf, s, 1, file);
          fwrite(buf, s, 1, to);              // <=
          ...
```

Приключения капитана Блада

В PVS-Studio размечено около 8000 C и C++ функций

- стандартная библиотека C
- стандартная библиотека шаблонов (STL)
- UE4 / UE5
- WinAPI
- glibc (GNU C Library)
- Qt
- MFC
- и т.д.

Это всё?

- Нет!
- Межпроцедурный анализ
- Способность статического анализатора раскрывать точки вызова функций и учитывать влияние таких вызовов на состояние программы и переменных в локальном проверяемом контексте.

Это всё?

- Нет!
- Межмодульный анализ
- Позволяет дать информацию анализатору о полной структуре проекта, делая анализ более точным и качественным.

Это всё?

- Нет!
- Taint-анализ
- Методика, позволяющая отследить распространение по программе внешних непроверенных данных (например, XML)

Опять-таки не всё, но хватит

- Свои разметки
- Разные стандарты классификации
  - CWE
  - CERT
  - MISRA

Ещё по этой теме


Андрей Карпов , Павел Еремеев

11 Янв 2022

Теги:
#StaticAnalysis

Технологии статического анализа кода PVS-Studio

- Абстрактное синтаксическое дерево (abstract syntax tree) и методика сопоставления с шаблоном (pattern-based analysis)
- Семантическая модель (semantic model) кода и вывод типов (type inference)
- Препроцессирование C и C++ исходного кода
- Отслеживание компиляции C и C++ исходного кода
- Анализ потоков данных (data-flow анализ) и символьное выполнение (symbolic execution)
- Межпроцедурный анализ
- Межмодульный анализ и аннотирование функций
- Taint-анализ (taint checking)
- Заключение
- Дополнительные ссылки

Межмодульный анализ C++ проектов

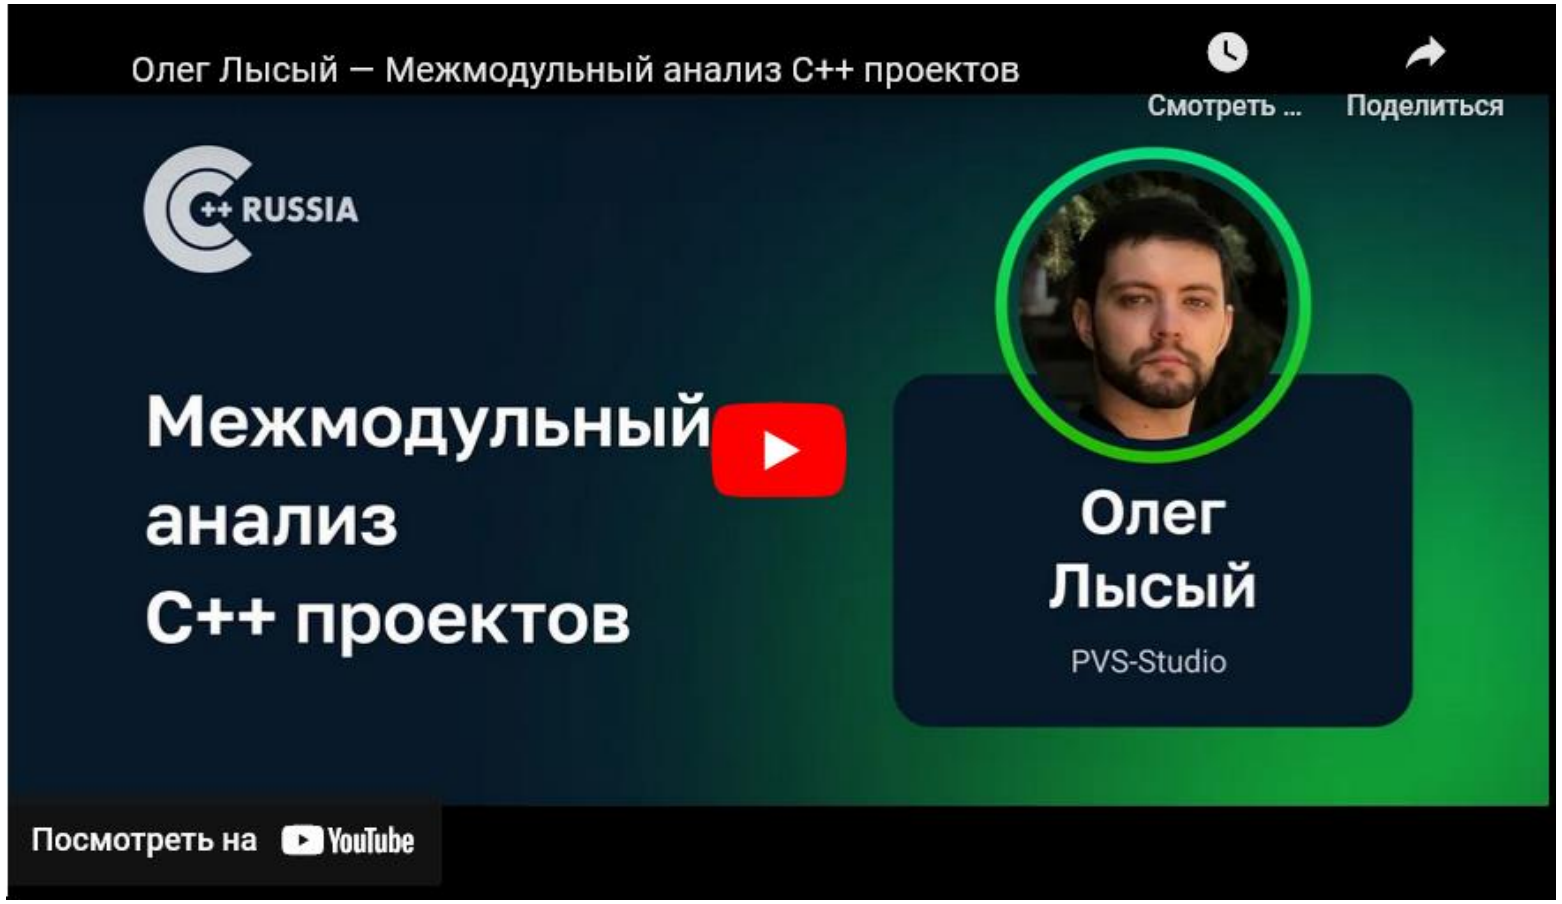

Q&A

feklin@viva64.com