Forráskód ellenőrzés

Majzik István
Budapesti Műszaki és Gazdaságtudományi Egyetem
Méréstechnika és Információs Rendszerek Tanszék
http://www.mit.bme.hu/~majzik/

Szoftvermodul kódolás

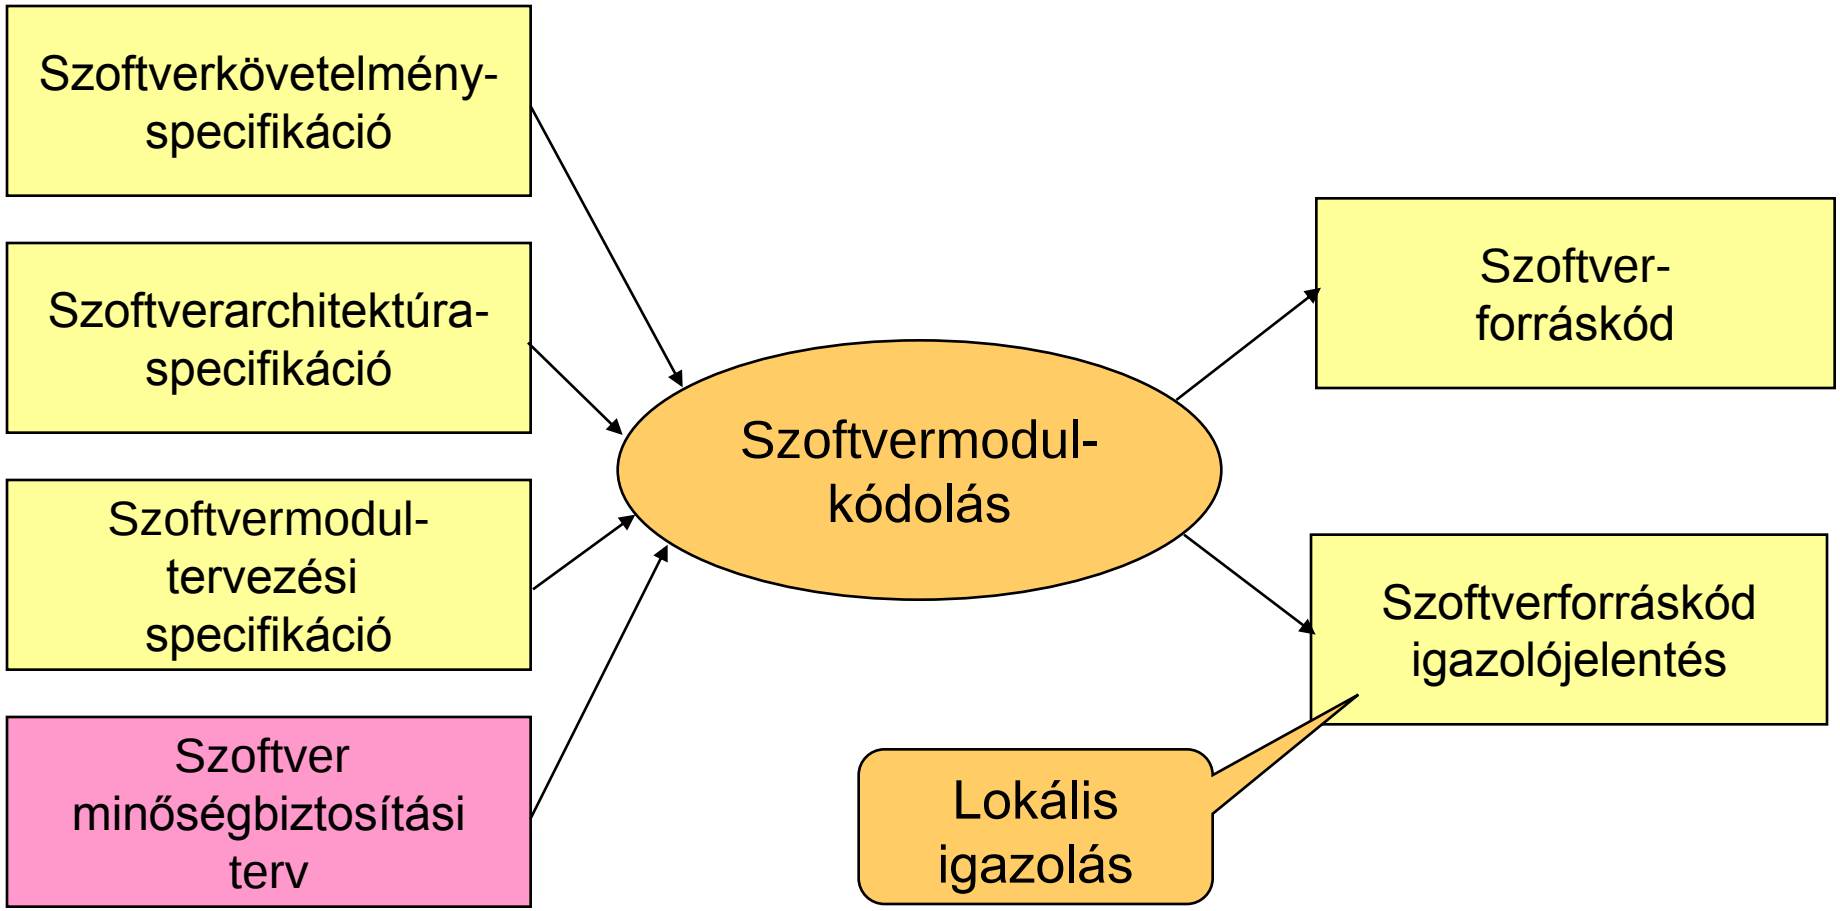

Fejlesztési szabványok tipikus előírásai

- Programozás:
  - Elemezhető programok: Egyszerű döntési feltételek
  - Erősen tipizált programnyelv: Típusellenőrzés
  - Strukturált programozás: Átlátható vezérlési szerkezetek
  - Objektum-orientált programozás
- Programozási nyelv (pl. EN50128 esetén):
  - SIL1-től HR: Ada, Modula-2, Pascal
  - SIL1-től NR: BASIC
  - SIL3-tól NR: BASIC, PLM, korlátozás nélküli C/C++
  - SIL3-tól R: C és C++ kódolási szabályokkal (nyelvi részhalmaz)
- Eszközök (fordítók, könyvtárak):
  - Validált vagy gyakorlatban bevált (HR)
  - Validálás: Compiler Verification Toolkit

Tipikus kódolási szabályok

- Irányelvek
  - Kód formázás, magyarázatok (kommentek)
  - Forráskód metrikák betartása
- Korlátozott konstrukciók
  - Rekurzió, mutatók használata
  - Automatikus típuskonverzió
  - Feltétel nélküli ugrás
- OO konstrukciók korlátozása
  - Polimorfizmus, többszörös öröklődés
  - Objektumok egymásba ágyazása
- Dinamikus konstrukciók tiltása
  - Objektumok futásidejű létrehozása illetve törlése

Példa: SoHaR kódolási szabályok (nukleáris ipar)

Group	Number	Guideline
	1	Reliability
	1.1	Predictability of Memory Utilization
Specific	1.1.1	Minimizing Dynamic Memory Allocation
Outside	1.1.2	Minimizing Memory Paging and Swapping
	1.2	Predictability of Control Flow
Specific	1.2.1	Maximizing Structure
Specific	1.2.2	Minimizing Control Flow Complexity
Specific	1.2.3	Initialization of Variables before Use
Specific	1.2.4	Single Entry and Exit Points in Subprograms
Specific	1.2.5	Minimizing Interface Ambiguities
Specific	1.2.6	Use of Data Typing
General	1.2.7	Precision and Accuracy
Specific	1.2.8	Use of Parentheses rather than Default Order of Precedence
Specific	1.2.9	Separating Assignment from Evaluation
Outside	1.2.10	Proper Handling of Program Instrumentation
General	1.2.11	Control of Class Library Size
General	1.2.12	Minimizing Dynamic Binding
General	1.2.13	Control of Operator Overloading
	1.3	Predictability of Timing
Outside	1.3.1	Minimizing the Use of Tasking
Outside	1.3.2	Minimizing the Use of Interrupt Driven Processing

Elterjedt C és C++ kódolási szabálykészletek

- MISRA C (Motor Industry Software Reliability Association)
  - Biztonságos C (2004): 141 szabály (121 szükséges)
  - Példák:
    - Rule 33 (Required): The right hand side of a "&&" or "||" operator shall not contain side effects.
    - Rule 49 (Advisory): Tests of a value against zero should be made explicit, unless the operand is effectively Boolean.
    - Rule 59 (R): The statement forming the body of an "if", "else if", "else", "while", "do ... while", or "for" statement shall always be enclosed in braces.
  - Eszközök a MISRA megfelelés ellenőrzéséhez
    - LDRA, PolySpace, IAR, …
- MISRA C++ (2008): 228 szabály
- US DoD, JSF C++: 221 szabály (kód metrikák is)
  - „Joint Strike Fighter Air Vehicle C++ Coding Standard”

Példa: MISRA megfelelőség ellenőrzése (IAR)

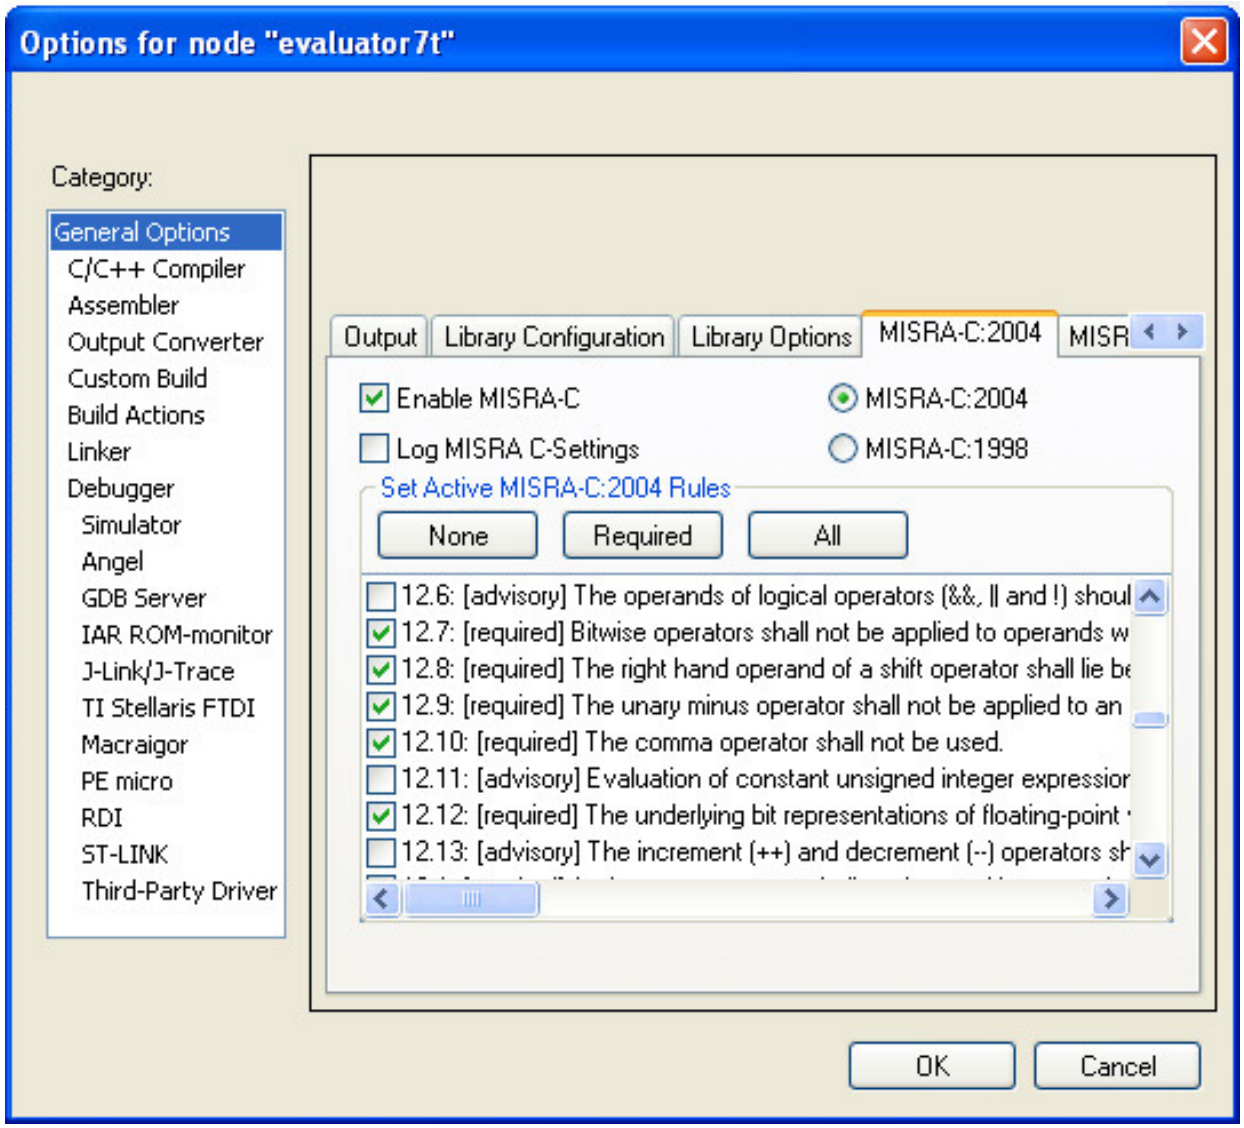

Példa: MISRA kódolási szabályok

- Kódsort nem szabad „kikommentezni”
  - Gondot okozhatnak az egymásba ágyazott kommentek
  - Nehezedik a forráskód érthetősége
- Ciklusváltozót nem szabad a ciklus belsejében módosítani

```
flag = 1;
for ( i = 0; (i < 5) && (flag == 1); i++ )
{
   /* ... */
   flag = 0;   /* Compliant - allows early termination of loop */
   i = i + 3;  /* Not compliant - altering the loop counter    */
}
```

- Tiltott nyelvi elemek:
  - goto,
  - continue
- Bitmanipuláló műveletet nem szabad signed, vagy floating típusokon végrehajtani (>>, <<, ~, &, ^)

Példa: Compiler sajátosságokra való felkészülés

- Egész osztások ellenőrzése és dokumentálása:
  - (-5/3) lehet -1 ahol a maradék -2, illetve
  - (-5/3) lehet -2 ahol a maradék +1
- Változók összeadásakor, szorzásakor kicsúszás az értéktartományból:

```
uint16_t u16a = 40000;          /* unsigned short / unsigned int ? */
uint16_t u16b = 30000;          /* unsigned short / unsigned int ? */
uint32_t u32x;                  /* unsigned int / unsigned long  ? */

u32x = u16a + u16b;             /* u32x = 70000 or 4464 ?          */
```

  - Az összeadás aritmetikáját nem az eredmény tárolási típusa, hanem a compiler belső aritmetikája (belső tárolás módja) határozza meg;
    pl. ha a belső aritmetika 16 bites, túlcsordulás történhet
- Különösen veszélyesek a bitmanipuláló műveletek

Szoftver metrikák

- Célkitűzések
  - Mérhető forráskód jellegzetességek meghatározása
  - Kapcsolatban vannak a forráskód minőséggel
- Minőségi szempontok metrikákhoz (MISRA)
  - Komplexitás
  - Karbantarthatóság
  - Modularitás
  - Megbízhatóság
  - Strukturáltság
  - Tesztelhetőség
  - Érthetőség
  - Kiérleltség
- A minőség mellett költségek is becsülhetők
  - Fejlesztés, tesztelés, módosítás költsége

Példa: MISRA metrikák

Software Attributes	Type of Technique	Area of Application	Technique or Metric
Structuredness	Method	Component Source Code	Interval Reduction
	Metrics	Component Source Code	Cyclomatic Number Essential Cyclomatic Complexity Number of Entry Points Number of Exit Points Number of Structuring Levels Number of Unconditional Jumps Number of Execution Paths
Testability	Metrics	Component Source Code	Cyclomatic Number Number of Distinct Operands Number of Unconditional Jumps Number of Execution Paths Number of Decision Statements IB Coverage DDP Coverage LCSAJ Coverage PPP Coverage
		System Source Code	Number of Calling Paths Number of Components IB Coverage DDP Coverage LCSAJ Coverage PPP Coverage

IB: Instruction blocks
DDP: Decision to decision paths
LCSAJ: Linear code sequences and jumps
PPP: Procedure to procedure paths

Példa: MISRA korlátok

Operátorok és operandusok átlagos száma utasításonként

Komponensek átlagos száma hívási szintenként

Software Metric	Area of Application	High Level Languages		Low Level Languages	
		Min	Max	Min	Max
Average Statement Size	Component	2	8	N/A	N/A
Comment Frequency	Component	0.5	1	1	1
Component Length	Component	3	250	3	250
Component Stress Complexity	Component	1	10000	1	10000
Cyclomatic Number	Component	1	15	1	15
DDP Coverage	Both	80%	100%	80%	100%
Essential Cyclomatic Complexity	Component	1	1	1	1
Hierarchical Complexity	System	1	5	1	5
IB Coverage	Both	100%	100%	100%	100%
LCSAJ Coverage	Both	60%	100%	60%	100%
Number of Calling Levels	System	1	8	1	8
Number of Calling Paths	System	1	250	1	250
Number of Components	System	1	150	1	150
Number of Decision Statements	Component	0	8	0	8
Number of Distinct Operands	Component	1	50	1	50
Number of Distinct Operators	Component	1	35	1	35

OO metrikák kategóriák szerint

- Méret: Forráskód elemek leszámlálása
  - Kódsorok, attribútumok, metódusok (private / public / protected)
- Komplexitás: Ciklomatikus számok
  - CK: Független utak maximális száma a vezérlési gráfban
  - Metódusok ciklomatikus komplexitásainak összege
- Csatolás: Egy-egy osztály hány más elemet használ
  - Közvetlenül hívott metódusok száma
  - Hívott metódussal vagy használt attribútummal rendelkező osztályok száma
- Öröklés: Öröklési gráf jellege
  - Adott osztály alatti, fölötti szintek száma, közvetlenül / összesen
  - Öröklött metódusok száma
- Kohézió: Osztály metódusai és attribútumai
  - Közös attribútumot használó metódusok száma
  - Egymást hívó saját metódusok száma

OO metrikák és a hibára való hajlam összefüggése

Kísérlet: Metrika és a hibaszám összefüggése osztályonként

- Nyílt forráskódú projektek (Mozilla, 4500 osztály) hibakövető rendszerében (Bugzilla) rögzített hibák (230 000) elemzése

- Hatékony előjelző metrikák osztályokra: Csatolás, méret kategóriák
  - CBO (Coupling Between Objects): Osztályok száma, amelyekhez kapcsolódik (használja a metódusát vagy attribútumát, vagy öröklődik)
  - RFC (Response Set of a Class): Az osztály metódusai + közvetlenül hívott metódusok száma
  - NOI (Number of Outgoing Invocations): A közvetlenül hívott metódusok
  - NFMA (Number of Foreign Methods Accessed): Közvetlenül hívott idegen, azaz nem saját és nem örökölt metódusok száma
  - NML (Number of Methods Local): Az osztály lokális metódusainak száma
  - LLOC (Logical Lines of Code): A nem üres és nem komment sorok száma
- Nem hatékony hiba előjelző metrikák: Öröklés, kohézió kategória
  - NOA (Number of Ancestors): Az ősosztályok száma
  - NOC (Number of Children): A közvetlen leszármazottak száma
  - LCOM (Lack of Cohesion in Methods): Metóduspárok száma, amelyek nem használnak közös attribútumot, mínusz amik használnak

Milyen technikái vannak a verifikációnak?

- Ellenőrző lista a kód átvizsgáláshoz (átolvasás)
  - Tipikus általános hibák keresése
  - Kódolási szabályok kézi ellenőrzése
  - Struktúra elemzése
    - Vezérlési folyam elemzés
    - Adatáramlás elemzése, határértékek elemzése
    - Hibabecslés
- Statikus analízis eszközök alkalmazása
  - Hibaminta keresés: Tipikusan szintaxis, részben szemantikai hibák
    - Adatáramlás: Inicializálás, foglalás és felszabadítás, …
    - Vezérlés: Elérhetetlen kódrészlet, …
  - Hibaminták bővítése a specifikus kódolási szabályokkal
  - Mértékek ellenőrzése
- Dinamikus tulajdonságok vizsgálata statikus analízissel
  - Változók értéktartományának vizsgálata
  - Teljesítményproblémák vizsgálata

Automatikus statikus analízis eszközök típusai

- Korai eszközök: kód „jólformáltság” ellenőrzésére
  - Lint (C-hez, 1979, Bell Labs)
  - JLint (Java) később
- Hibaminta keresők
  - Beépített hibaminták + bővíthetők újabb hibamintákkal
  - Nem adnak garanciát a hibamentességre
  - Nem biztonságosak (pl. kimaradó hibák, téves jelzések)
  - Példák: FindBugs, PMD (Java), Gendarme (.Net CIL), …
- Absztrakt kód interpretációt támogató eszközök
  - Túlcsordulás, túlcímzés, redundáns feltételek ellenőrzése
    - CodeSurfer, CodeSonar (C/C++, template alapú)
    - Prevent: MS COM, Win32 API, PThreads támogatása
    - Klocworks

Példa: FindBugs hibakategóriák és példák

- Bad practice
  - Random object created and used only once
- Correctness
  - Bitwise add of signed byte value
- Malicious code vulnerability
  - May expose internal static state by storing a mutable object into a static field
- Multithreaded correctness
  - Synchronization on Boolean could lead to deadlock
- Performance
  - Method invokes toString() method on a String
- Security
  - Hardcoded constant database password
- Dodgy
  - Useless assignment in return statement

Példa: PMD szabályok bővítése

```
class Example {
    void bar() {
        while (baz)
            buz.doSomething();
    }
}
```

Szeretnénk, ha jelezné, amikor a while blokk körül nincsenek kapcsos zárójelek

```
public class WhileLoopsMustUseBracesRule extends AbstractRule {
  public Object visit(ASTWhileStatement node, Object data) {
    SimpleNode firstStmt = (SimpleNode)node.jjtGetChild(1);
    if (!hasBlockAsFirstChild(firstStmt)) {
      addViolation(data, node);
    }
    return super.visit(node,data);
  }
  private boolean hasBlockAsFirstChild(SimpleNode node) {
    return (node.jjtGetNumChildren() != 0 && (node.jjtGetChild(0) instanceof ASTBlock));
  }
}
```

A szabály Java-ban kódolva

- AST reprezentáción dolgozik
- Beillesztendő a szabályok közé az AST adott helyén

Egy példa futtatás

```
public class Main {
    public static void chk(boolean s1, boolean s2){
        if(s1 = s2) {System.out.println("foo");}
        else {System.out.println("bar");}}
    public static void main(String[] args) {
        boolean b1 = false;
        boolean b2 = true;
        Main.chk(b1, b2);}}
```

'==' helyett '='

JLint:

Verification completed: 0 reported messages.

FindBugs:

The parameter s1 to Main.chk(boolean, boolean) is dead upon entry but overwritten at Main.java:[line 5]

Dead store to s1 in Main.chk(boolean, boolean) At Main.java:[line 5]

PMD:

No problems found!

Dinamikus tulajdonságok statikus verifikációja

Motiváció:

- Hibák, problémák megállapítása a program végrehajtása (tesztelése) nélkül
- Analógia:
  Optimalizáló fordítókban használatos elvek
  - Élő (használatos) változók megállapítása
    - Egy regiszterbe kerülhetnek, amelyek nem egyszerre élnek
  - Azonos értéket hordozó változók azonosítása
    - Konstansok használata változó olvasás helyett
  - Sokszor használt rész-kifejezések keresése
    - Újraszámítás optimalizálható

Statikusan detektálható futásidejű hibák

- Null pointer
- Tartományból kilógó pointer
- Tartományból kilógó tömbindex
- Inicializálatlan adat olvasása
- Hozzáférési konfliktus megosztott változókon
- Aritmetikai hiba
  - Nullával osztás
  - Negatív szám négyzetgyöke
  - Inverz szögfüggvények érvénytelen adatokon ...
- Alulcsordulás, túlcsordulás
- Veszélyes típuskonverzió
- Kivételkezelés problémái
- Nem elérhető kód

Példa: PRQA QA-C, QA-C++ eszközök

Security Issues:

- Buffer under- and overflow
- Arithmetic overflow and wraparound
- Format string mis-use

Crash-Inducing Defects:

- Null pointer operations, invalid pointer values, operations on unrelated pointers
- Divide-by-zero
- Uncaught exceptions, throw-catch specification mismatches, improper exception use

Flawed Logic Issues:

- Invariant (always true/false) logic and unreachable code
- Unset variables
- Redundant expressions, initializations and assignments
- Infinite loops
- Return value mismatches

Memory Issues:

- Memory allocation mismatches
- Memory leaks

API Mis-use:

- Standard library pre- and post-condition verification

„A combination of SMT solver and in-house language and parsing expertise result in exceptionally accurate dataflow and semantic modelling of C and C++ code – a foundation for a set of unique analysis checks.”

Példa: Detektálható futásidejű hiba

```
20: int ar[10];
21: int i,j;
22: for (i=0; i<10; i++)
23: {
24:   for (j=0; j<10; j++)
25:   {
26:     ar[i-j] = i+j;
27:   }
28: }
```

Out-of-bound array access in line 26

Hogyan működik a statikus analízis?

Vizsgált forráskód:

```
0: k=ioread32();
1: i=2;
2: j=k+5;
3: while (i<10) {
4:       i=i+1;
5:       j=j+3;
6: }
7:
8: k = k/(i-j);
```

Kockázatos:
0-val való osztás.
Előfordulhat-e?

Mit tudunk a változók értékeiről?

- $X0=\{(0,0,k) \mid k \in [-2^{31}, 2^{31}-1]\}$
- $X1=\{(2,j,k) \mid (i,j,k) \in X0\}$
- $X2=\{(i,k+5,k) \mid (i,j,k) \in X1\}$
- $X3= X2 \cup X6$
- $X4=\{(i+1,j,k) \mid (i,j,k) \in X3,\ i<10\}$
- $X5=\{(i,j+3,k) \mid (i,j,k) \in X4\}$
- $X6= X5$
- $X7=\{(i,j,k) \mid (i,j,k) \in X3,\ i \geq 10\}$
- $X8=\{(i,j,k) \mid (i,j,k) \in X7,\ i-j \neq 0\}$
- $X8_{error}=\{(i,j,k) \mid (i,j,k) \in X7,\ i-j=0\}$

Mik lehetnek (i,j,k) értékei

Előző lépés alapján

Két helyről jöhet ide a program

Ciklus belseje

Ciklusból kilépés

A tartományok kiszámítása I.

- $X0=\{(0,0,k) \mid k \in [-2^{31}, 2^{31}-1]\}$

  $X0=\{(0,0,k) \mid k \in [-2^{31}, 2^{31}-1]\}$
- $X1=\{(2,j,k) \mid (i,j,k) \in X0\}$

  $X1=\{(2,0,k) \mid k \in [-2^{31}, 2^{31}-1]\}$
- $X2=\{(i,k+5,k) \mid (i,j,k) \in X1\}$

  $X2=\{(2,k+5,k) \mid k \in [-2^{31}, 2^{31}-1]\}$
- $X3= X2 \cup X6$

  $X3=\{(i,j,k) \mid k \in [-2^{31}, 2^{31}-1], i \in [2,10], j=k+3i-1\}$
- $X4=\{(i+1,j,k) \mid (i,j,k) \in X3, i<10\}$

  $X4=\{(i,j,k) \mid k \in [-2^{31}, 2^{31}-1], i \in [3,10], j=k+3i-4\}$

X0 által nyújtott információ figyelembevétele

Értékadás a ciklusig és ciklus belseje

j=k+5+3(i-2) a ciklusban

j még nem kapott értéket, 3 levonva

A tartományok kiszámítása II.

- $X5=\{(i,j+3,k) \mid (i,j,k) \in X4\}$

  $X5=\{(i,j,k) \mid k \in [-2^{31}, 2^{31}-1], i \in [3,10], j=k+3i-1\}$

- $X6= X5$

  $X6=X5$

- $X7=\{(i,j,k) \mid (i,j,k) \in X3, i \geq 10\}$

  $X7=\{(10,j,k) \mid k \in [-2^{31}, 2^{31}-1], j=k+29\}$

- $X8=\{(i,j,k) \mid (i,j,k) \in X7, i-j \neq 0\}$

  $X8=\{(10,j,k) \mid k \in [-2^{31}, 2^{31}-1], j=k+29, i-j \neq 0\}$

- $X8_{error}=\{(i,j,k) \mid (i,j,k) \in X7, i-j=0\}$

  $X8_{error}=\{(10,10,-19)\}$

j=k+3i-1,
itt i=10

i-j=0: k=-19 esetén hiba ☹

Az ellenőrzés alapelvei

- Adatfolyam alapú ellenőrzés
  - Tartományokkal (kényszerekkel) történő műveletek
  - Ciklus invariánsok felhasználása
- Általános nyelvekre az invariánsok számítása nem triviális
  - A megállási probléma erre visszavezethető lenne
  - Közelítő számítások szükségesek
- A valódinál bővebb tartományok (lefedő tartományok) biztonságosan használhatók
  - Lehetséges hibahelyek nem maradnak ki: Hibahely esetén nem jelez hibamentességet (bővebb halmazból nem szökik meg a hiba)
  - Téves hibajelzés lehetséges: Ezek részletes analízisére van szükség (pl. teszteléshez tippet ad)
  - Kód színezés: „biztosan jó”, „biztosan hibás”, „gyanús” helyek

Általános problémakör: Közelítő tartományok

- Probléma: Osztás (x-y) értékkel (x=y vizsgálat kell)

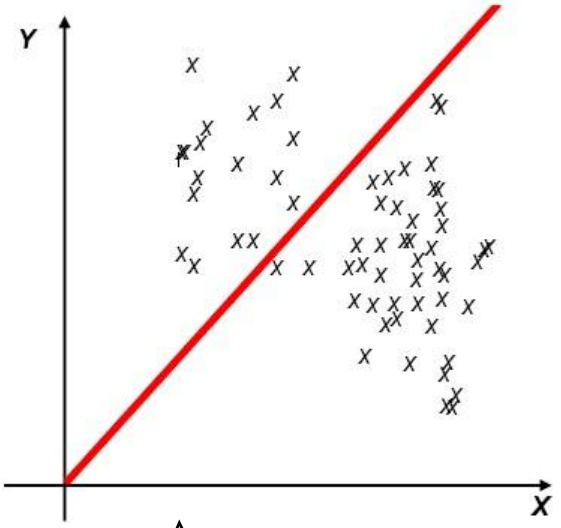

Eredeti állapottér

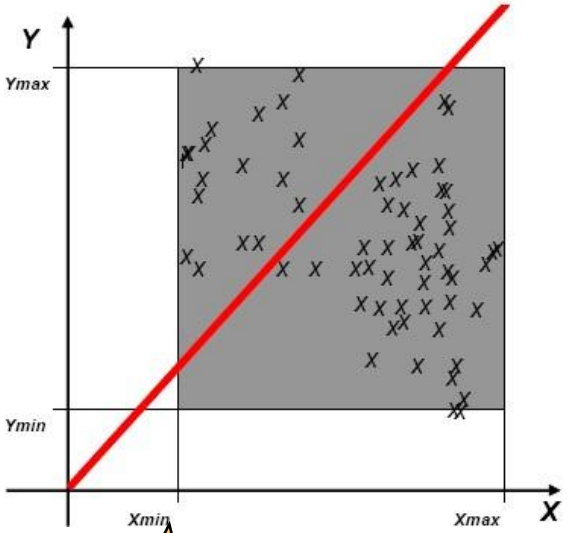

Durva közelítés (nem célszerű)

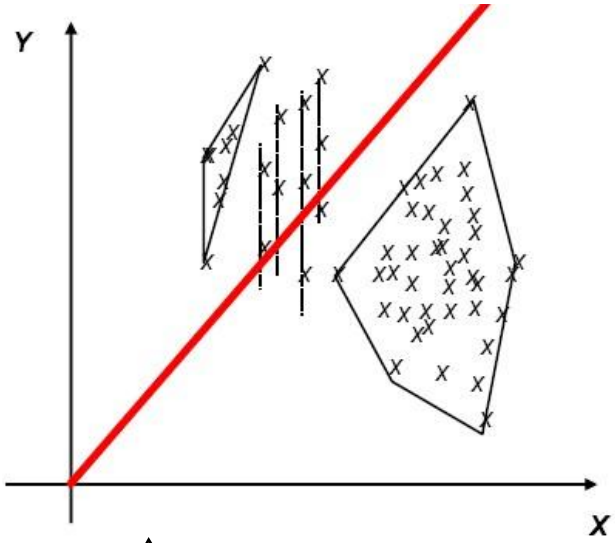

Alkalmas közelítés (4 eset finomítandó)

PolySpace eszköz

```
static void Square_Root_conv (double alpha, float *beta_pt, float *gamma)
{
  *beta_pt = (float)((1.5 + cos(alpha))/5.0);

  if(*beta_pt < 0.3)
  *gamma = 0.75;
}

static void Square_Root (void)
{
  double alpha = random_float();
  float beta;
  float gamma;

  Square_Root_conv (alpha, &beta, &gamma);

  if(random_int() > 0){
     gamma = (float)sqrt(beta - 0.75);
  }
  else{
     gamma = (float)sqrt(gamma - beta);
     if(beta > 1)
            alpha = 0;
  }
}
```

The Colors of PolySpace

Each function and operation is verified for **all** possible values, and then colored according to its reliability.

Green **Proven** safe under **all** operating conditions. Focus your efforts elsewhere.

Red **Proven** definite error each time the operation is executed.

Orange **Unproven.**

Grey **Proven** unreachable code. May point to a functional issue.

- Statikus analízis és kód színezés
- MISRA kódolási szabályok ellenőrzése

Kód interpretációt támogató eszközök

- Absztrakt interpretációt támogató eszközök:
  - PolySpace C/Ada
    - Ariane 5 (70k kódsor), Flight Management System (500k kódsor)
  - Astrée
    - Airbus flight control software
  - C Global Surveyor
    - NASA Mars PathFinder, Deep Space One
- Annotáció alapú eszközök (design by contract):
  Ciklus invariánsok, elő- és utófeltételek explicit bevitele
  - ESC/Java (JML alapján)
  - Microsoft PreFix, PreFast, Boogie (Spec#, BoogiePL)
- Használatuk előnyei:
  - Statikusan detektált futásidejű hibák (tesztelés előtt)
  - Robusztussági problémák felderítése
  - Kód mértékek nyerhetők a minőség becsléséhez
  - Annotáció alapján monitor kód, teszt oracle is generálható
    - Pl. jmlc+jmlrac, jmlunit