OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Mise à plat de graphes de flot de contrôle et exécution symbolique

SSTIC 2013

L'auteur

- Eloi Vanderbeken
- @elvanderb

- Ingénieur SSI
- Oppida : Conseil et expertise en sécurité des systèmes d'information

- Reverse-engineering
- Cryptographie appliquée
- Obfusca… brouillage !

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Plan

- Introduction
- Approche proposée
- Implémentation pratique
- Résultats

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Introduction

- Plusieurs niveaux de brouillage de code
- Techniques *bas niveau* :
  - Agissent directement sur le code assembleur.
  - Pas ou peu d'informations contextuelles.
  - Ex : insertion de code mort, couches de chiffrement, mutation / virtualisation de code, etc.

  → Méthodes générique de débrouillage (optimisation du code, approche concolique etc.)
- Techniques *haut niveau* :
  - Nécessitent des informations contextuelles :
    - Etats de variables globales ;
    - Graphe de flot de contrôle ;
    - Effets de bord des fonctions ;
    - etc.
  - Problèmes indécidables ;
  - Ex : mise a plat de graphe de flot de contrôle, prédicats opaques utilisant des variables globales, etc.

  → Pas de méthodes génériques.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Mise à plat de graphe de flot de contrôle

- Méthode décrite formellement par Wang en 2000.
- Les relations entre les blocs ne sont pas directement visibles.
- Un (ou plusieurs) gestionnaire(s) se charge(nt) d'aiguiller le flot d'exécution.
- L'aiguillage est fait à l'aide de variables initialisées / modifiées par le code précédemment exécuté.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Mise à plat de flot de contrôle en une image

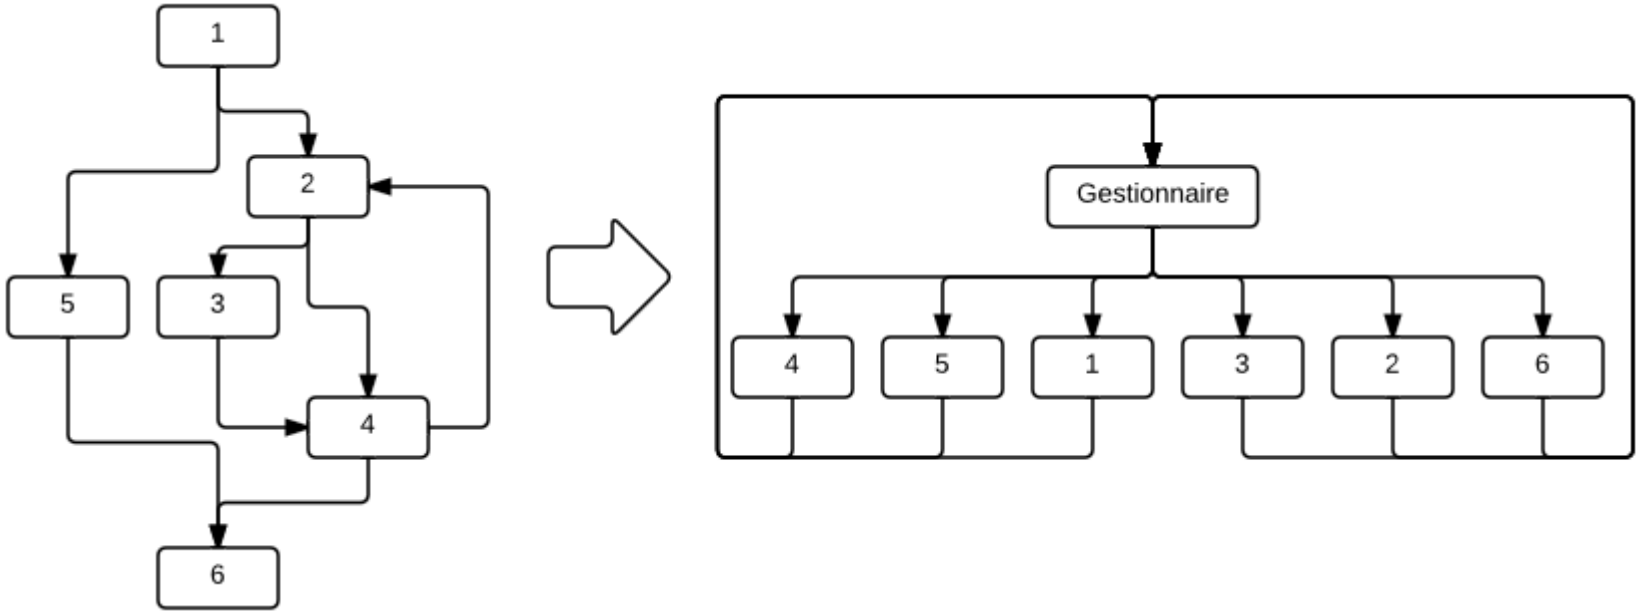

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Mise à plat de flot de contrôle en une image (ou deux)

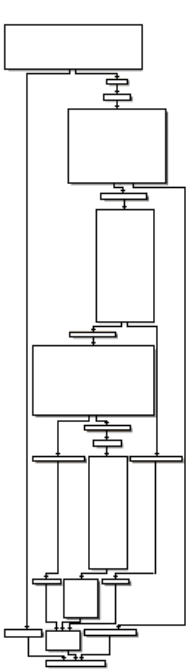

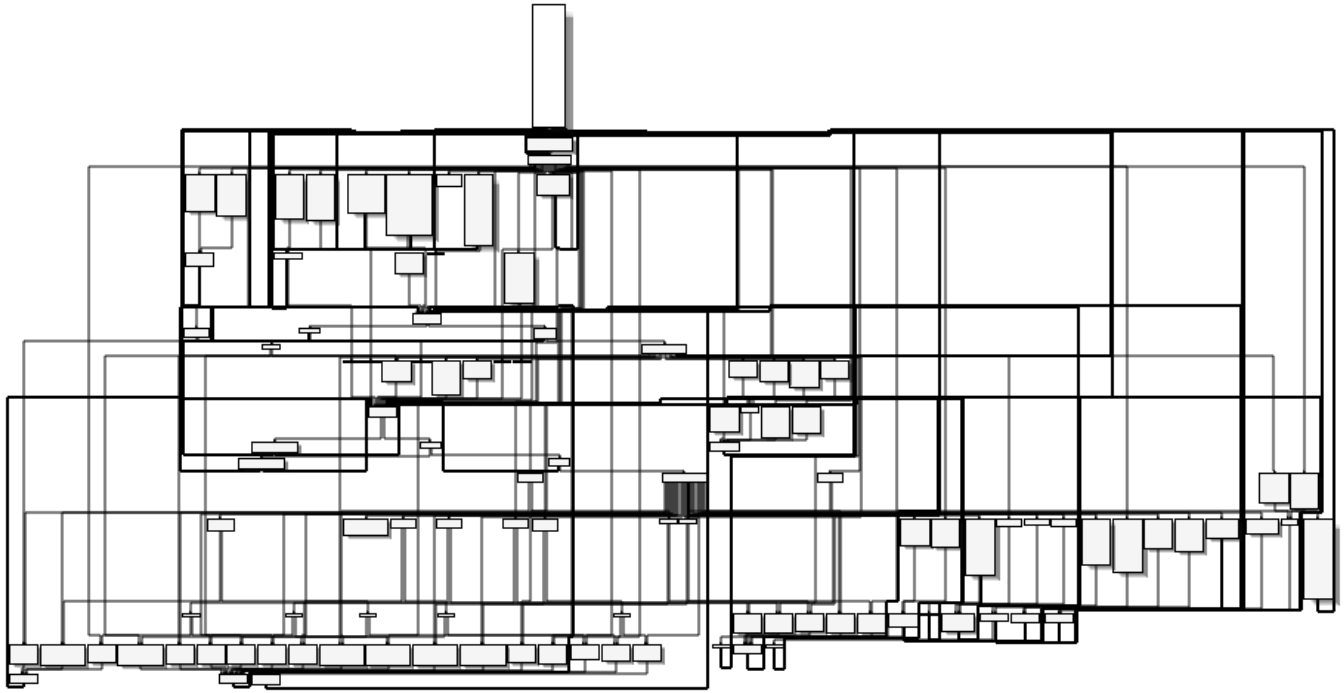

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Approches possibles …

- Dynamique avec suivit d'exécution
- Dynamique avec suivit de donnée
- Statique avec de l'exécution symbolique.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Approche dynamique avec suivit d'exécution

- Principe :
  - Exécution de la fonction brouillée ;
  - Enregistrement de l'enchainement des basic blocks ;
  - Reconstruction du CFG original.
- Avantages :
  - Rapide ;
  - Précis ;
  - « Simple »
- Inconvénients :
  - Nécessite d'identifier les gestionnaires ;
  - Ne donne pas les conditions de branches ;
  - N'est pas exhaustif.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Approche dynamique avec suivit de donnée

- Principe :
  - Exécution de la fonction brouillée ;
  - Enregistrement des opérations sur les données ;
  - Le flot d'exécution est ignoré.
- Avantages :
  - Précis ;
  - *Relativement* simple.
- Inconvénients :
  - Ne donne pas la structure du code ;
  - N'est toujours pas exhaustif ;
  - Peu efficace en cas d'opérations mathématiques complexes.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Approche choisie – l'approche statique

- Principe :
  - Considération de l'ensemble des entrées possibles ;
  - Suivi du flot d'exécution de la fonction à partir de ces entrées ;
  - Reconstruction du CFG original à partir de ces informations.
- Avantages :
  - Exhaustif ;
  - Permet d'avoir une vision plus abstraite du code ;
  - Fournit les conditions de branche ;
  - Elégant ☺.
- Inconvénients :
  - Parfois trop abstrait :
    - quelle est la valeur de `PC` après l'instruction `ADD PC, R0, [SP + Sym]` ?
  - Complexe et lourd.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Quelques notions …

- Traces
- Basic Blocks
- Exécution symbolique

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Trace

- Proche de la notion de trace de Pin :
  - une entrée ;
  - plusieurs sorties ;
  - composée de Basic Blocks (BBl);
  - pas de boucle.
- Mais différentes :
  - Les traces sont des arbres.
  - En cas de branche conditionnelle, la trace contient les deux branches.
  - Une trace est terminée par un gestionnaire.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Basic Block

- Différents des Bbl « classiques ».

- Suite d'instructions à une entrée et une sortie.
- Un bloc de base est identifié par son adresse de début **et par son parent**.
- Caractérisé par son contexte initial.
- Peut contenir des instructions de branches conditionnelles :
  - Si le contexte initial ne permet pas plusieurs flux d'exécution différents.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Principe de reconstruction du graphe

- Exécution symbolique du code.
- Si instruction conditionnelle dans le contexte donné :
  - Fin de *Basic Block*.
- Si instruction de fin de gestionnaire :
  - Fin de *Trace*.
- Si instruction précédemment exécutée :
  - Fusion des contextes.
- Sinon ajout de l'instruction au *Basic Block* courant.

Un exemple en image

```
for (i = 0; i < 10; i++)
    printf("foo\n");
printf("bar");
```

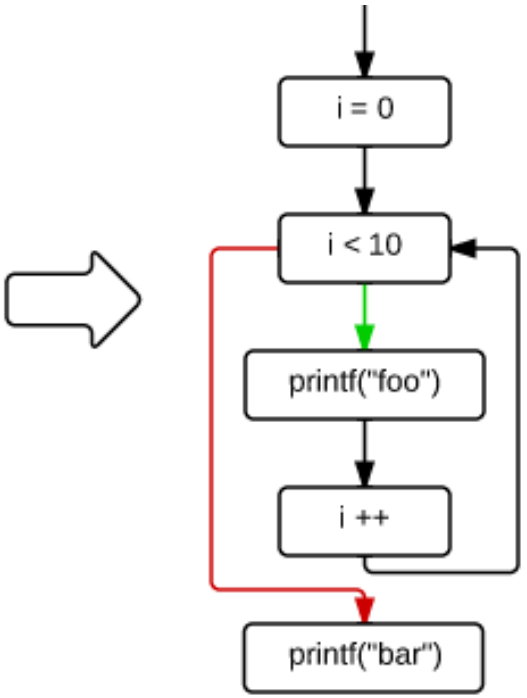

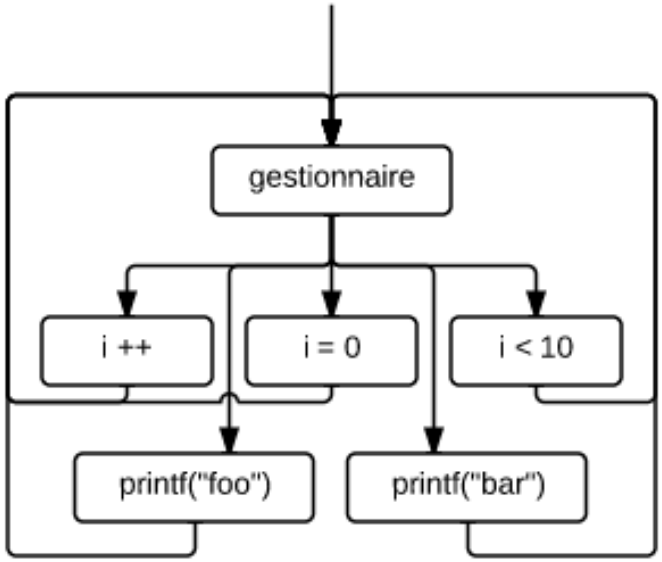

Un exemple en image

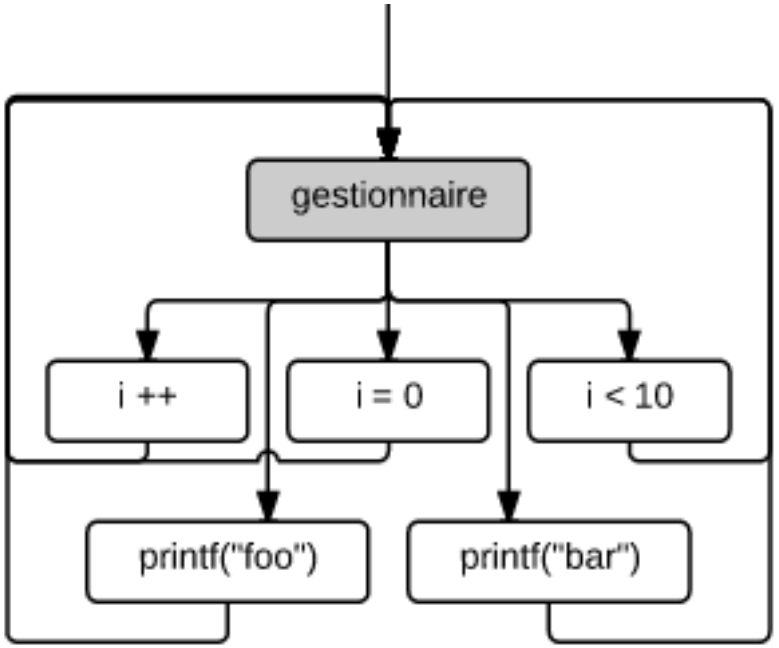

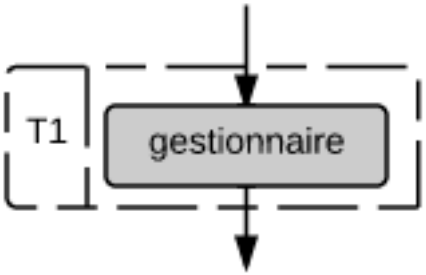

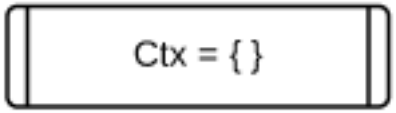

Un exemple en image

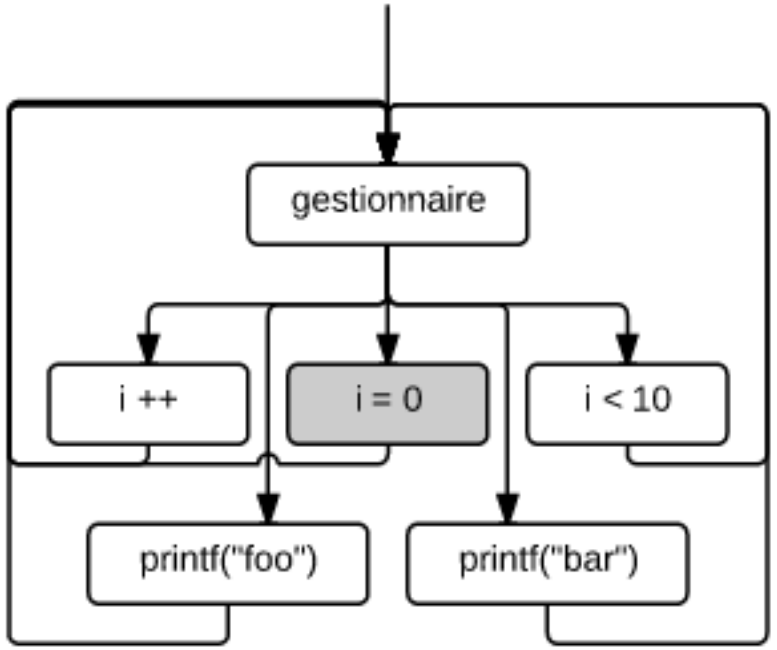

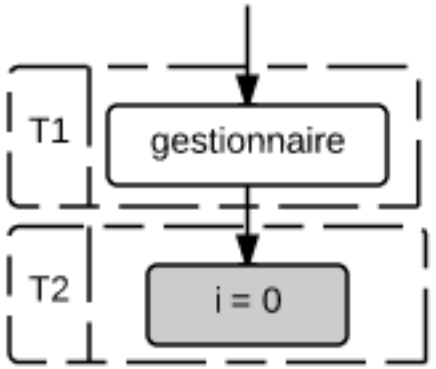

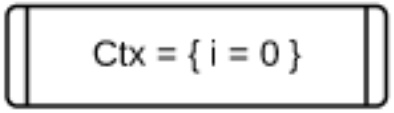

Un exemple en image

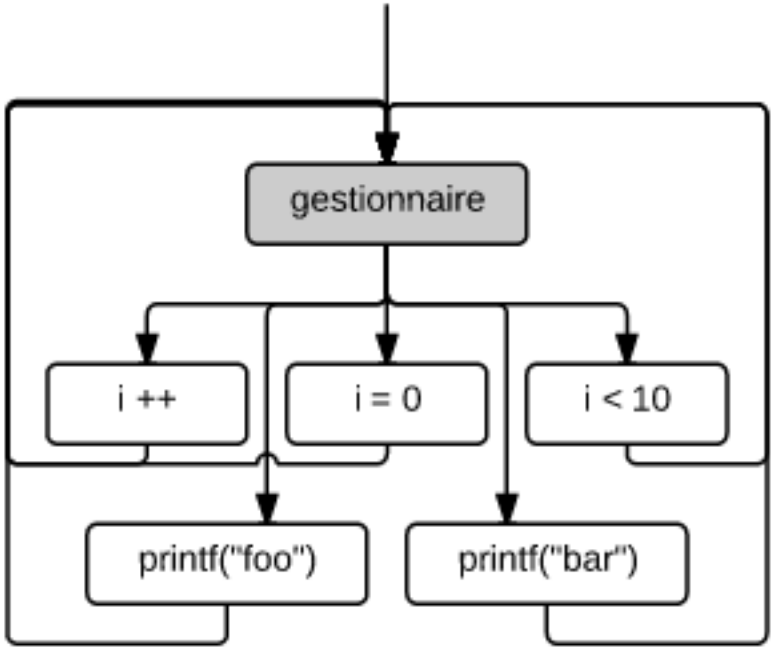

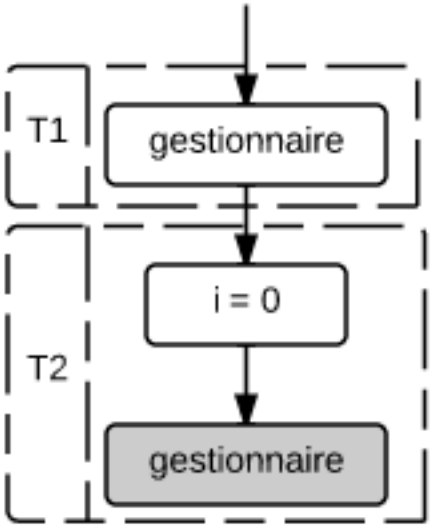

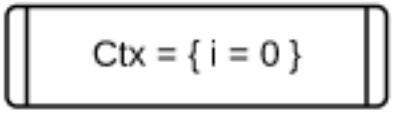

Un exemple en image

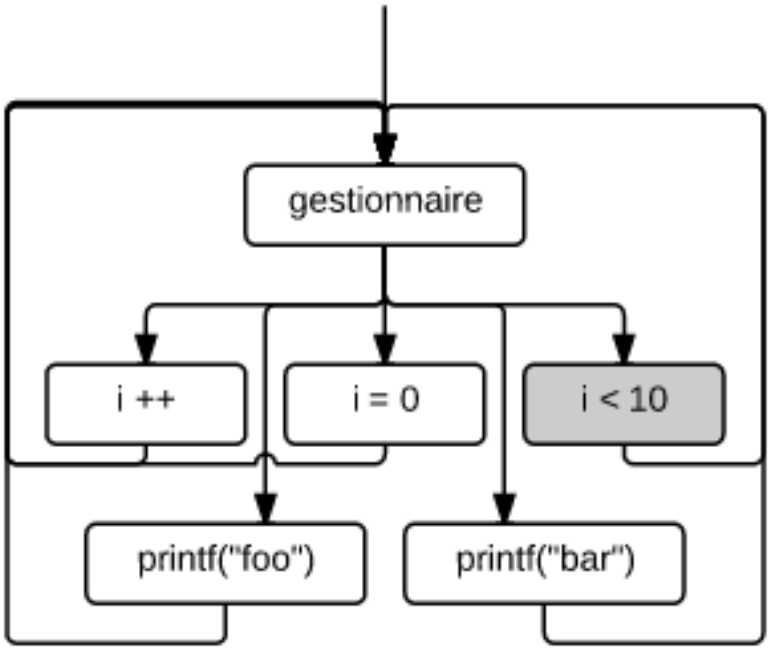

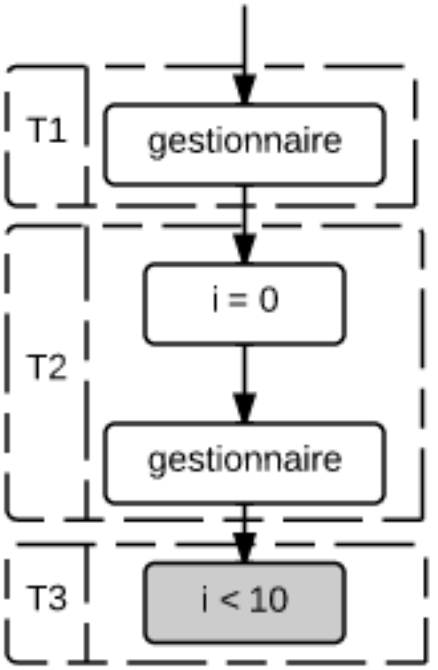

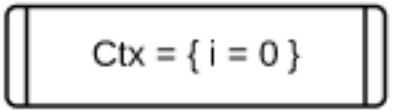

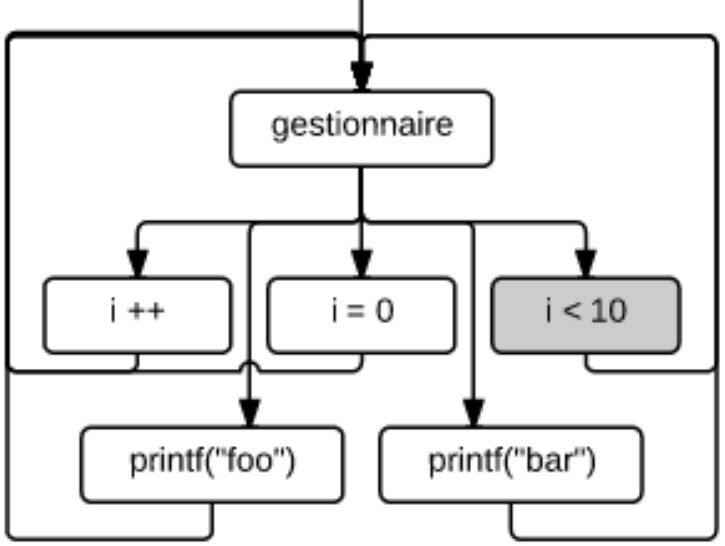
gestionnaire
i ++
i = 0
i < 10
printf("foo")
printf("bar")

Ctx = { i = 1 }

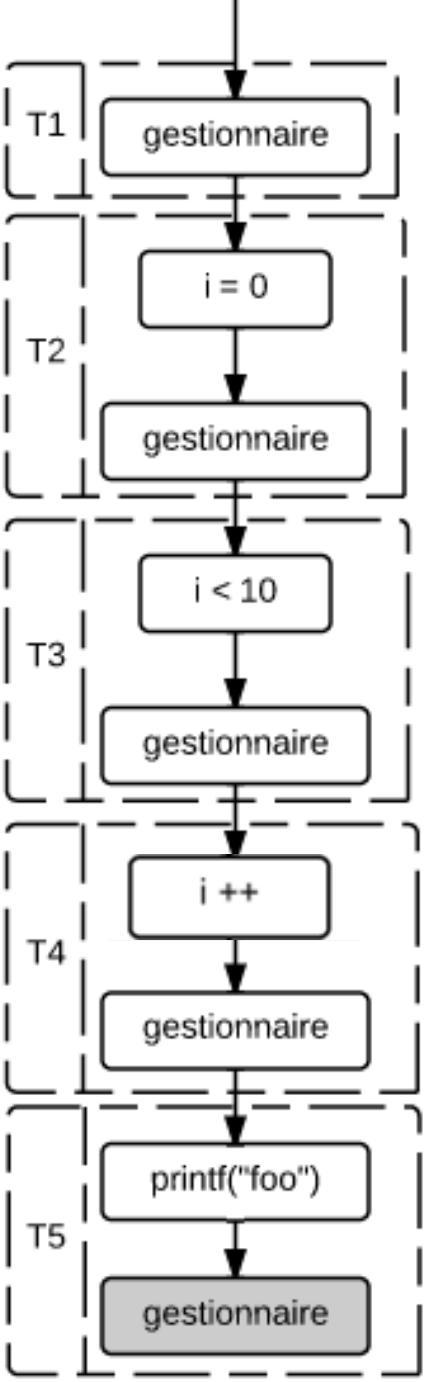
T1
gestionnaire
T2
i = 0
gestionnaire
T3
i < 10
gestionnaire
T4
i ++
gestionnaire
T5
printf("foo")
gestionnaire

Un exemple en image

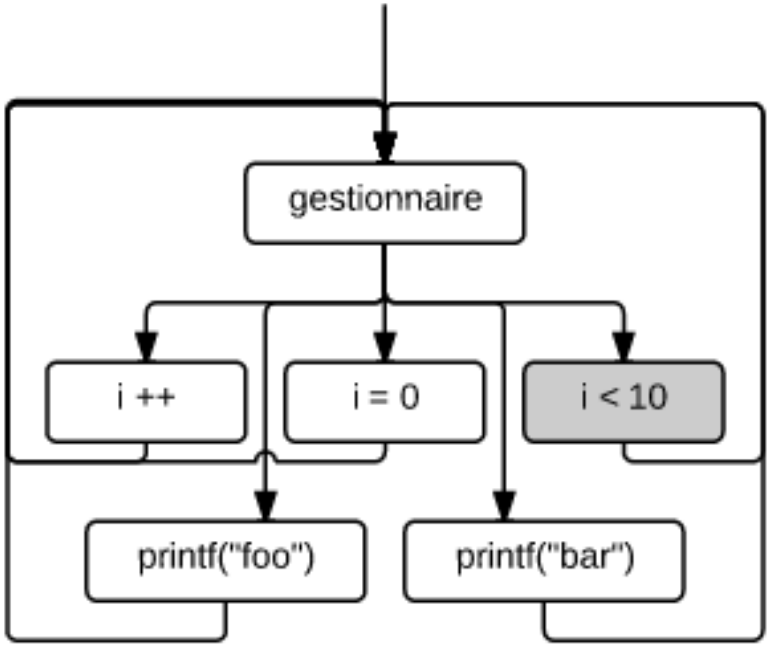

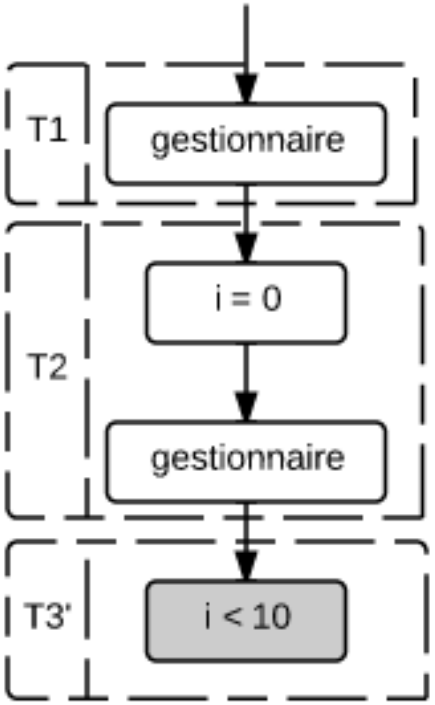

$Ctx = \{ i = i\_sym_{T3} \}$

Un exemple en image

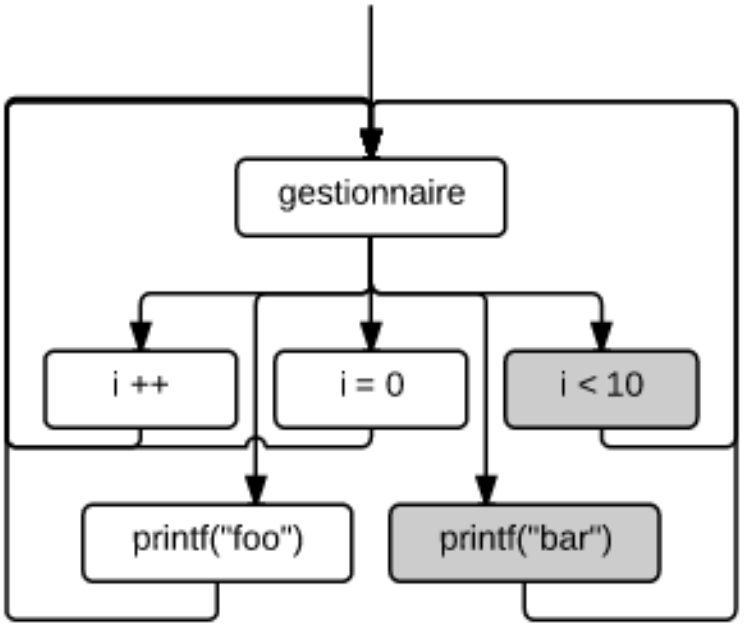

$Ctx = \{ i = i\_sym_{T3} \}$

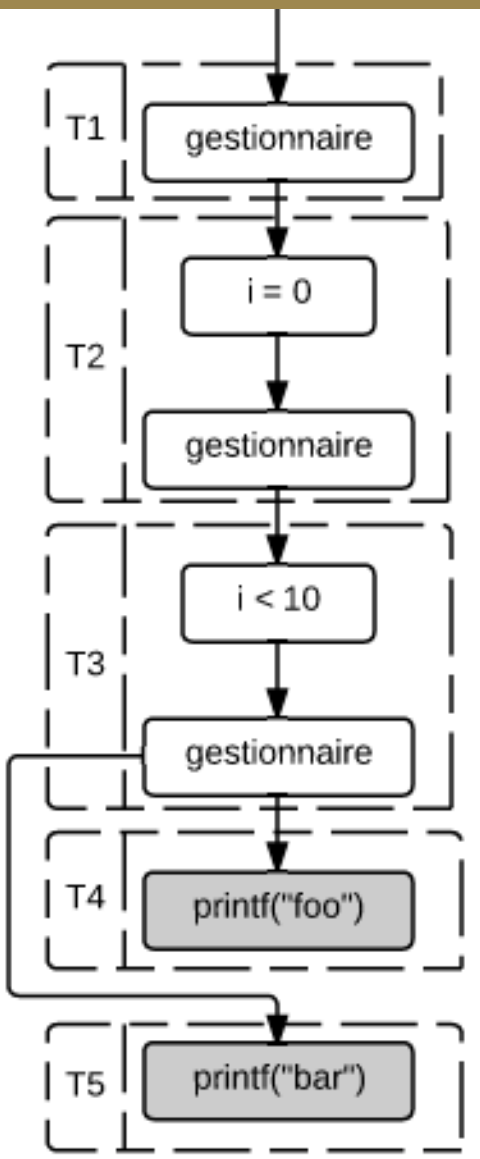

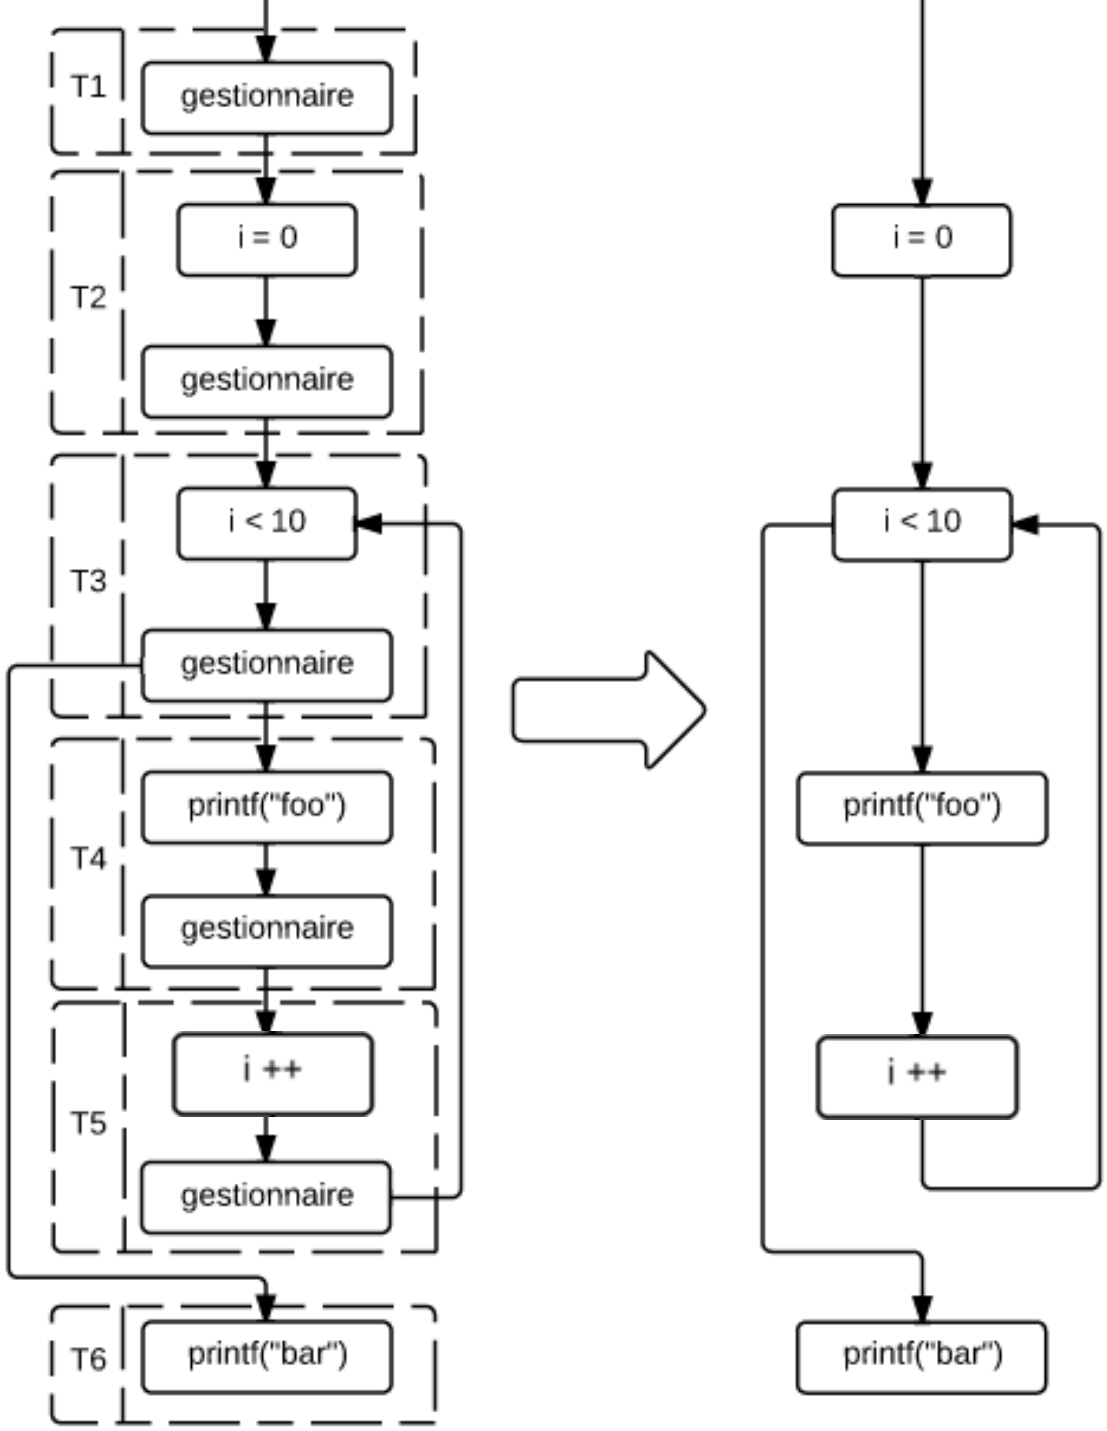
T1
gestionnaire
T2
i = 0
gestionnaire
T3
i < 10
gestionnaire
T4
printf("foo")
gestionnaire
T5
i ++
gestionnaire
T6
printf("bar")
i = 0
i < 10
printf("foo")
i ++
printf("bar")

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Implémentation concrète

- Gestion des références à des adresses symboliques ?
- Gestion des appels aux fonctions externes ?
- Simplification / résolution des équations ?
- Simplification du code ?
- Identification des gestionnaires ?
- Extraction de la sémantique des instructions ?

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

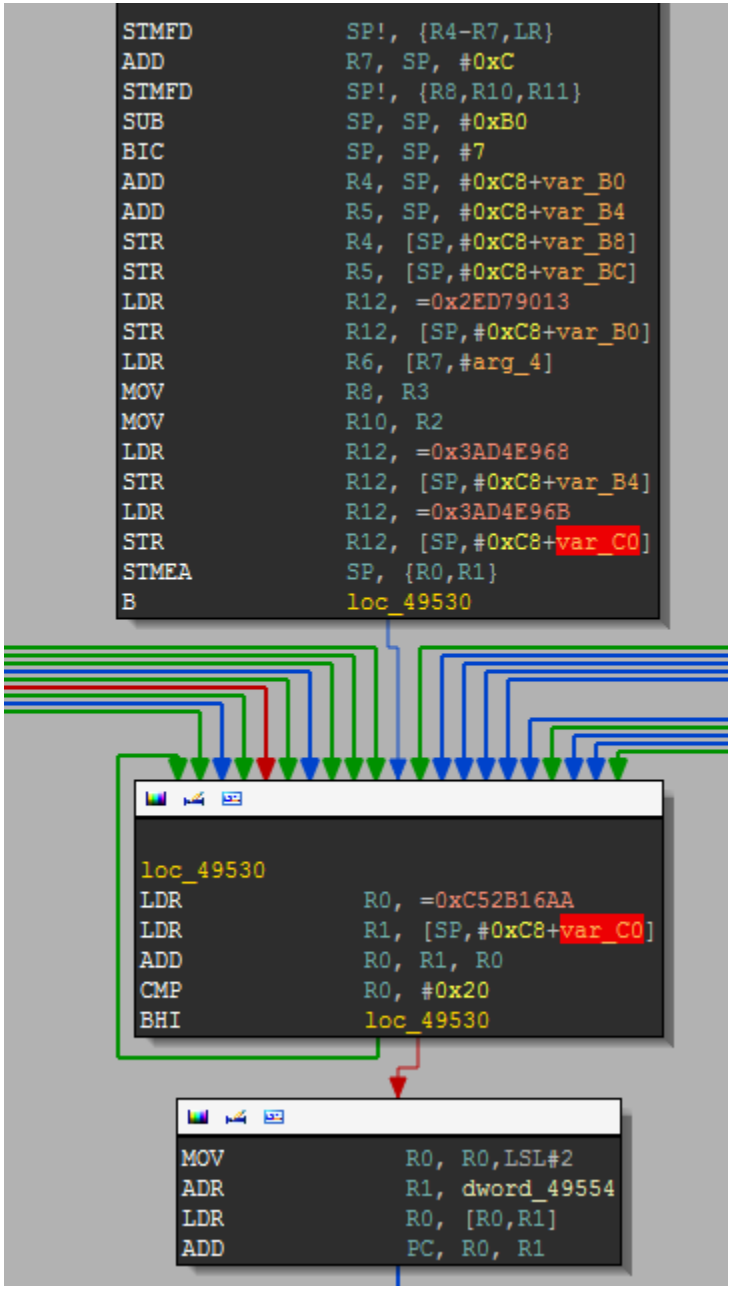

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

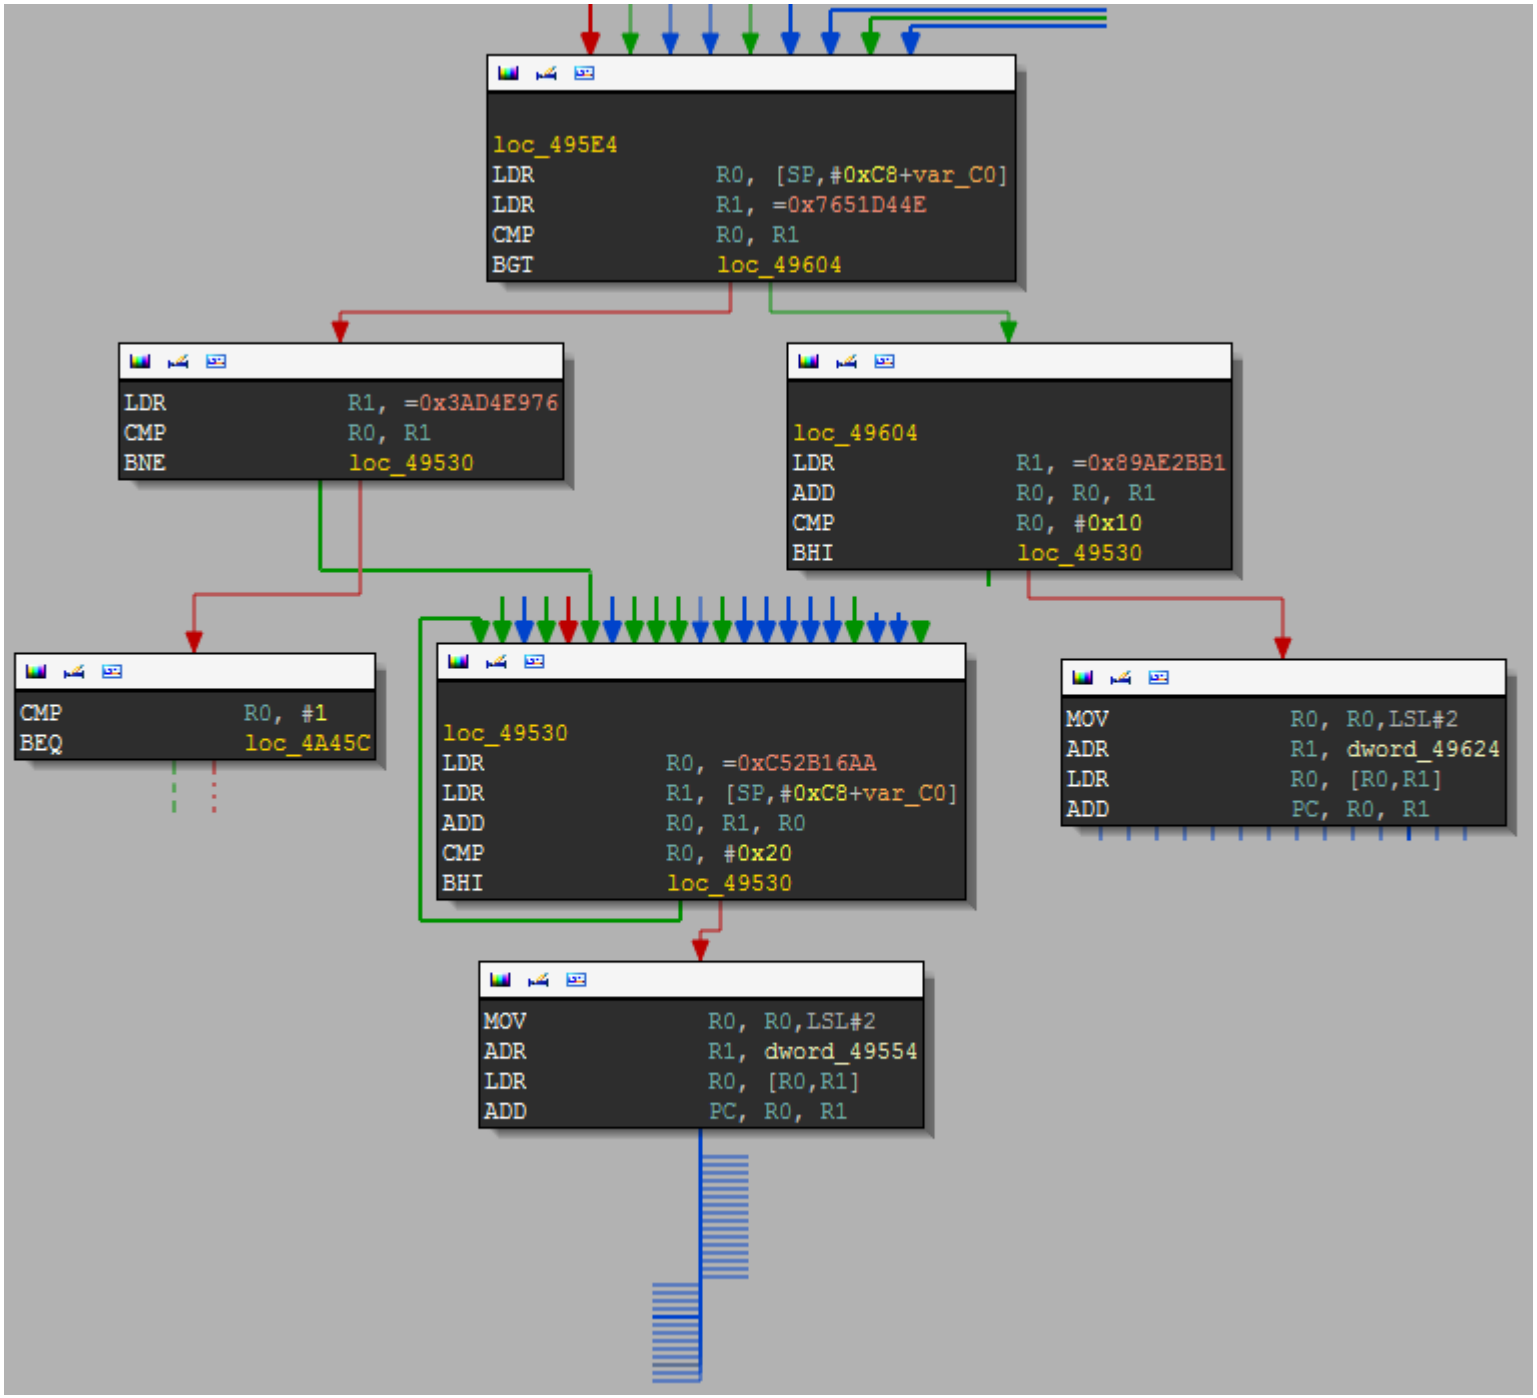

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Traduction IDA → Objet python

- Pas si simple qu'il n'y parait :
  - Documentation pauvre voir inexistante.
  - Réutilisation de champs prévus pour d'autres architecture.
    - Condition d'exécution dans le champ `segpref`
- Instruction résumée à l'aide de 3 types d'objets :
  - Opcode (`MOV`, `OR`, `B` etc.)
  - Condition d'exécution (`NZ`, `CC`, `GE` etc.)
  - Opérande(s) (`R0`, `0x1234`, `R0 LSL R3`, `[SP!, 0x456]` etc.)
- Description de la sémantique des instructions à l'aide de ces objets.
  - Simple et rapide.
  - N'a à être effectuée qu'une seule fois.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Exemple : implémentation d'une instruction

```
class Bic(Ins) :
  __metaclass__ = MetaIns

  def _emu(self, context) :
    # les conditions d'exécution sont vérifiées par Ins.emu
    if len(self.ops) != 3 :
      raise EmulationException("%s is not supported yet"%self)
    dest = self.ops[0]
    src1 = self.ops[1]
    src2 = self.ops[2]
    v = context[src1] & ~context[src2]
    context[dest] = v
    if self.affect_flags :
      context.flags.N = v.N
      context.flags.Z = v.Z
```

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Contexte symbolique

- Basé sur Z3
  - solveur d'équations SAT développé par Microsoft ;
  - supporte les vecteurs de bits et l'arithmétique associée ;
  - performant ;
  - possède une interface python.
- Les registres et cases mémoire sont des valeurs de 32 bits.
- Les flags sont des booléens.
- Pile et reste de la mémoire dissociés
  - `SP` est une valeur symbolique.
  - Imprécision :
    - Une adresse absolue pourrait correspondre à la pile ;
    - Une adresse relative à SP pourrait correspondre à une variable globale ;
    - En pratique ce n'est jamais le cas : imprécision acceptable.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Contexte symbolique – accès mémoire en lecture

- Si l'adresse à déréférencer est concrète :
  - Mémoire globale ;
  - Lecture de la valeur dans la base de IDA.
- Si l'adresse est symbolique :
  - Détermination des valeurs possibles de l'adresse à l'aide de Z3 ;
  - Si SP intervient dans le calcul de l'adresse :
    - Il s'agit d'une adresse dans la pile ;
    - Soustraction de `SP` à l'adresse et calcul des deltas possibles.
  - Si plus de `N` valeurs possibles, abstraction de la valeur ;
  - Sinon construction de la valeur déréférencée :
    - `If(addr_sym == addr_concrete1, Dword(addr_concrete1), If(addr_sym == addr_concrete2, stack[addr_concrete2-SP], …, ∅)`

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Exemples de déréférencement

```
a = arg0 & 1; /* a = arg0 & 1 */
b = "ab"[a];
/* b = If(arg0 & 1 == 0, 'a', If(arg0 & 1 == 1, 'b', ∅)) */

c = ((DWORD*)arg0)[1];
/* c = sym_deref_(arg0+4) */
```

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Contexte symbolique – accès mémoires en écriture

- Si l'adresse à déréférencer est concrète :
  - Mémoire globale ;
  - Interdit dans notre modèle :
    - Pourrait être implémenté facilement.
- Si l'adresse est symbolique :
  - Détermination des valeurs possibles de l'adresse ;
  - Si moins de `N` valeurs possibles :
    - `stack[addr_concrete1-SP] = If(addr_sym == addr_concrete1, new_value, orig_value1)`
    - `stack[addr_concrete2-SP] = If(addr_sym == addr_concrete2, new_value, orig_value2)`
    - etc.
  - Sinon ?

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Exemples de déréférencement

```
char t[4];
a = arg0 & 3;
/* a = arg0 & 3 */
t[a] = 1;
/* a = arg0 & 3 */
/* t[0] = If(arg0 & 3 == 0, 1, sym_deref_(t)) */
/* t[1] = If(arg0 & 3 == 1, 1, sym_deref_(t+1)) */
/* t[2] = If(arg0 & 3 == 2, 1, sym_deref_(t+2)) */
/* t[3] = If(arg0 & 3 == 3, 1, sym_deref_(t+3)) */
arg0[arg1] = 3;
/* ??? */
```

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Contexte symbolique – écriture à une adresse symbolique

- Nécessaire de déterminer quelles variables sont invariantes :
  - lors d'un appel à une fonction inconnue ;
  - lors d'une écriture mémoire à une adresse symbolique.
- Considérer toutes les variables invariantes :
  - Toutes les exécutions possibles ne seront pas considérées :
    - Toutes les branches ne seront pas nécessairement explorées.
    - `b = FALSE; f_set_bool(&b); if (b) { /* non exploré */ }`
- Considérer toutes les valeurs volatiles :
  - Sûre mais potentiellement *trop* abstrait :
    - `a = 0; f_foo(b); func_table[a](); // adresse de la fonction appelée ?`

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Contexte symbolique – écriture à une adresse symbolique

- Définition « à la main » des invariants :
  - Sûre si l'analyse est correcte.
- Heuristique :
  - Seules les valeurs à haute entropie (identifiants des successeurs) et les pointeurs sur la pile sont gardés.
  - Les autres variables sont considérées comme volatiles.
  - Non sûre mais fonctionne en pratique.
- En pratique :
  - utilisation de l'heuristique et vérification à la main.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

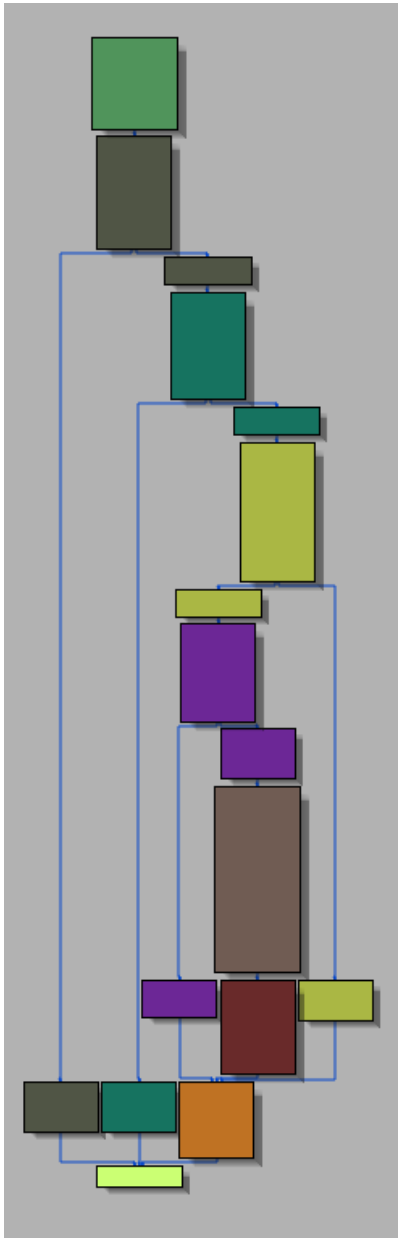

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Simplification du CFG

- Exécution symbolique de toutes les traces.
- Enregistrement de toutes les modifications :
  - Registres, mémoire.
- Génération des conditions de saut :
  - simplification de `PC_sym == PC_concret`
- Optimisation de la trace générée :
  - La simplification des formules est fournie *gratuitement* par Z3.
  - Les fonctions non connues sont supposées respecter la convention d'appel cdecl :
    - Toutes les variables locales sont considérées comme potentiellement utilisées.
    - Les registres `R0`, `R1`, `R2`, `R3` et `R12` sont considérés comme potentiellement utilisés.
  - Suppression des affectations inutiles :
    - Si une variable ou un registre a est initialisé et n'est pas utilisé avant sa prochaine initialisation alors l'initialisation est inutile.
  - Suppression des blocs vides.

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

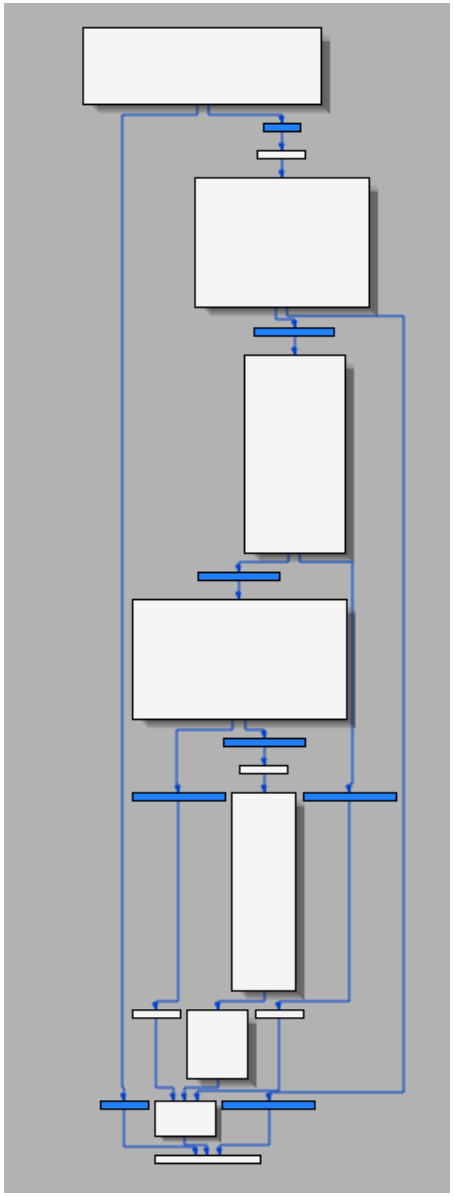

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

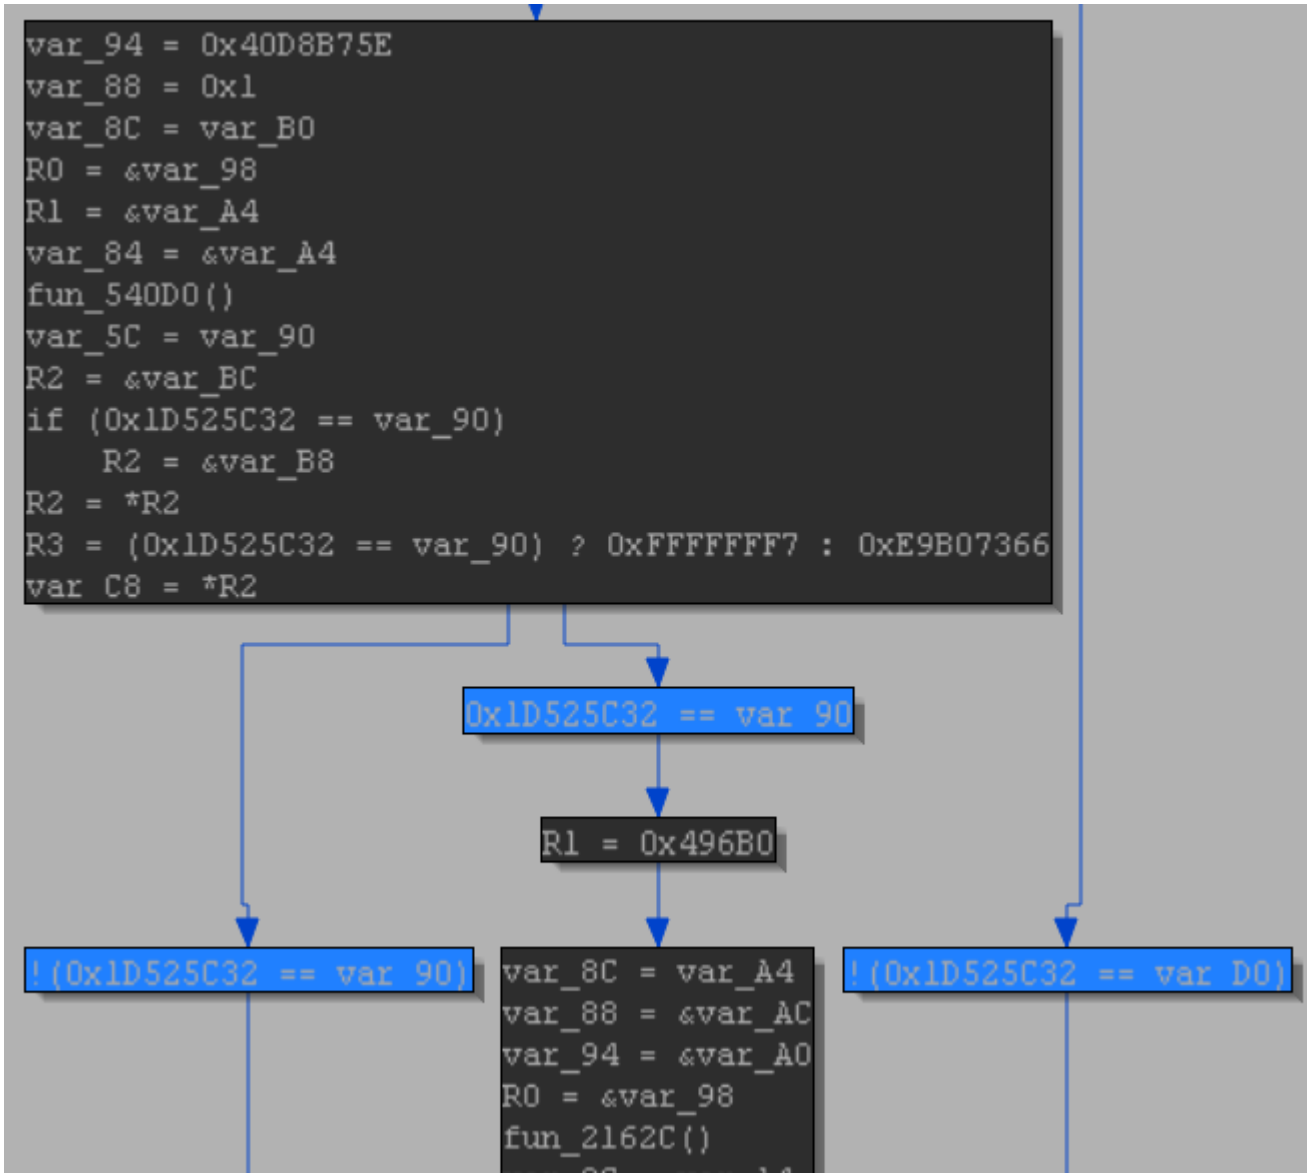

Démo

Conclusion

OPPIDA
EXPERT EN SÉCURITÉ
DES SYSTÈMES D'INFORMATION

Merci de votre attention

(et à Jean Sigwald ☺)

Questions ?