



# Les POMDP font de meilleurs hackers: Tenir compte de l'incertitude dans les tests de penetration

Carlos Sarraute, Olivier Buffet, Joerg Hoffmann

## ► To cite this version:

Carlos Sarraute, Olivier Buffet, Joerg Hoffmann. Les POMDP font de meilleurs hackers: Tenir compte de l'incertitude dans les tests de penetration. Olivier Buffet. Journées Francophones sur la planification, la décision et l'apprentissage pour le contrôle des systèmes - JFPDA 2012, May 2012, Villers-lès-Nancy, France. 14 p, 2012. <hal-00735608>

**HAL Id: hal-00735608**

**<https://hal.inria.fr/hal-00735608>**

Submitted on 26 Sep 2012

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Les POMDP font de meilleurs hackers: Tenir compte de l'incertitude dans les tests de pénétration

Carlos Sarraute<sup>1</sup>, Olivier Buffet<sup>2</sup>, Jörg Hoffmann<sup>3</sup>

<sup>1</sup> Core Security & ITBA  
Buenos Aires, Argentina  
carlos@coresecurity.com  
<http://corelabs.coresecurity.com/>

<sup>2</sup> INRIA / Université de Lorraine  
LORIA, Nancy, France  
olivier.buffet@loria.fr  
<http://www.loria.fr/~buffet/>

<sup>3</sup> Saarland University  
Saarbrücken, Germany  
hoffmann@cs.uni-saarland.de  
<http://www.loria.fr/~hoffmanj/>

**Résumé** : Les tests de pénétration sont une méthodologie pour évaluer la sécurité d'un réseau en générant et exécutant de possibles attaques informatiques. Automatiser cette tâche permet de réaliser des tests réguliers et systématiques. Une question clef est : "Comment générer ces attaques ?" Ce problème se formule naturellement comme de la planification dans l'incertain, plus précisément avec une connaissance incomplète de la configuration du réseau. Les travaux antérieurs emploient de la planification classique, et requièrent de coûteux pré-traitements réduisant cette incertitude par l'application extensive de méthodes de scan. Au contraire, nous modélisons ici le problème de la planification d'attaques à travers des processus de décision markoviens partiellement observables (POMDP). Ceci nous permet de raisonner à propos de la connaissance disponible, et d'employer intelligemment les actions de scan comme faisant partie de l'attaque. Comme on s'y attendrait, cette solution précise ne passe pas à l'échelle. Nous concevons donc une méthode qui repose sur les POMDP pour trouver de bonnes attaques sur des machines individuelles, lesquelles sont recomposées en une attaque sur le réseau complet. Cette décomposition exploite la structure du réseau dans la mesure du possible, faisant des approximations ciblées (seulement) où cela est nécessaire. En évaluant cette méthode sur un jeu de tests industriels adaptés convenablement, nous démontrons son efficacité à la fois en temps de calcul et en qualité de la solution.

## 1 Introduction

Les tests de pénétration (le *Penetration Testing*, ou *pentesting*) sont une méthodologie pour évaluer la sécurité d'un réseau en générant et exécutant de possibles attaques exploitant des vulnérabilités connues des systèmes d'exploitation et des applications (voir, par exemple, (Arce & McGraw, 2004)). Automatiser cette tâche permet des tests réguliers et systématiques sans un travail humain prohibitif et rend le pentesting plus accessible aux non-experts. Une question clef est : "Comment générer ces attaques ?"

Une façon naturelle de résoudre cette question est sous la forme d'un problème de *planification d'attaques*. C'est connu dans la communauté de la planification automatique comme le domaine de la "Cyber Sécurité" (Boddy *et al.*, 2005). Indépendamment (mais bien plus tard), l'approche a été mise en avant aussi par Core Security (Lucangeli *et al.*, 2010), une compagnie de l'industrie du pentesting. Sous cette forme, la planification d'attaques est très technique, s'attachant aux détails de bas niveau de la configuration système qui sont pertinents pour les vulnérabilités. Ici nous nous intéressons exclusivement à ce cadre. Nous considérons le pentesting régulier automatique tel que conduit dans l'outil "Core Insight Enterprise" de Core Security. Nous utiliserons le terme "planification d'attaques" dans ce sens.

Lucangeli *et al.* (2010) encodent la planification d'attaques en PDDL et utilise des planificateurs prêt-à-l'emploi. Ceci est, en soi, déjà utile – en fait, c'est actuellement employé dans le produit commercial Core Insight Enterprise, reposant sur une variante de Metric-FF (Hoffmann, 2003). Toutefois, cette approche est limitée par son incapacité à gérer l'incertitude. L'outil de pentesting ne peut être à jour sur tous les détails de la configuration de chaque machine dans le réseau, lesquelles sont maintenues par des utilisateurs individuels.

Core Insight Enterprise résoud cela par l'utilisation extensive de méthodes de *scan* comme pré-traitement à la planification, qui ne considère alors que des *exploits*, c'est-à-dire des actions de piratage modifiant l'état du système. Les inconvénients de cela sont (a) ce pré-traitement entraîne des coûts importants en termes de temps d'exécution et de trafic réseau, et (b) de toute façon, puisque les scans sont imparfaits, il reste une incertitude résiduelle (Metric-FF est lancé sur la base de la configuration qui semble la plus probable). Un travail antérieur (Sarraute *et al.*, 2011b) a résolu (b) en associant à chaque exploit une probabilité de succès. Cela ne permet pas de modéliser les dépendances entre exploits, et requiert quand même des scans extensifs (pour obtenir des probabilités de succès réalistes) et ne résoud donc pas (a). Ici, nous fournissons la première solution capable de résoudre à la fois (a) et (b), mêlant intelligemment scans et exploits comme un vrai hacker le ferait. L'intuition fondamentale est que le pentesting peut être modélisé naturellement comme la résolution d'un POMDP.

Nous encodons la connaissance incomplète comme une incertitude sur l'état, modélisant ainsi les configurations possibles du réseau à l'aide d'une distribution de probabilités. Scans et exploits sont déterministes puisque leurs résultats dépendent seulement de l'état dans lequel ils sont exécutés. Des récompenses négatives encodent le coût (la durée) des scans et exploits ; des récompenses positives encodent la valeur des cibles atteintes. Ce modèle incorpore des pare-feux, des effets de bord préjudiciables des exploits (plantage de programmes ou de machines complètes), et les dépendances entre exploits reposant sur des vulnérabilités similaires.

Les solveurs de POMDP ne passent pas à l'échelle pour de grands réseaux. Cela n'est pas surprenant – même le modèle en entrée croît exponentiellement avec le nombre de machines. Nous montrons comment résoudre cela en exploitant la structure du réseau. Nous voyons les réseaux comme des graphes dont les nœuds sont des sous-réseaux complètement connectés, et dont les arcs encodent les connections entre ceux-ci, filtrées par des pare-feux. Nous décomposons ce graphe en composants bi-connectés. Nous approximations les attaques sur ces composants en combinant des attaques sur des sous-réseaux individuels. Nous approximations ces dernières en combinant des attaques sur des machines individuelles. Ces approximations sont conservatives, c'est-à-dire qu'elle ne surestiment jamais la valeur de la politique retournée. Les attaques sur des machines individuelles sont modélisées et résolues comme des POMDP, et les solutions sont propagées vers les plus hauts niveaux. Nous évaluons cette approche sur un jeu de tests industriels de Core Insight Enterprise, montrant que, en comparaison avec un modèle POMDP global, elle améliore largement le temps de calcul à un faible coût en termes de qualité d'attaque.

Nous présentons ci-après quelques préliminaires. Nous décrivons ensuite notre modèle POMDP, notre algorithme de décomposition, et nos résultats expérimentaux, avant de conclure cet article.

## 2 Préliminaires

Nous présentons quelques notions sur la structure du réseau et le pentesting, et donnons un rapide aperçu des POMDP.

### 2.1 Structure du réseau

Les réseaux informatiques peuvent être vus comme des graphes orientés dont les nœuds sont donnés par un ensemble  $M$  de *machines*, et dont les arcs sont des connections entre paires de  $m \in M$ . Toutefois, en pratique, ces graphes de réseaux ont une structure particulière. Ils tendent à être constitués de *sous-réseaux*, c'est-à-dire de groupes  $N$  (pour *Network*) de machines dans lesquels chaque  $m \in N$  est directement connecté à chaque  $m' \in N$ . À l'inverse, tout sous-réseau  $N$  n'est pas connecté à n'importe quel autre sous-réseau  $N'$  et, typiquement, si une telle connexion existe, elle est alors filtrée par un *pare-feu*.

Du point de vue d'un attaquant, les pare-feux filtrent les connexions et limitent ainsi les attaques qui peuvent être exécutées quand on essaye de pénétrer un sous-réseau  $N'$  depuis un autre sous-réseau  $N$ . D'autre part, une fois que l'attaquant a réussi à s'introduire dans un sous-réseau  $N$ , l'accès à toutes les

machines dans  $N$  est facilité. Ainsi, une représentation naturelle du réseau, du point de vue de la planification d’attaques, est celle d’un graphe dont les nœuds sont des sous-réseaux, et dont les arcs sont annotés avec des pare-feux  $F$  (pour *Firewall*). Nous appellerons ici ce graphe le *réseau logique*  $LN$  (pour *Logical Network*), et dénotons ces arcs avec  $N \xrightarrow{F} N'$ .

Nous formalisons les pare-feux comme des ensembles de règles décrivant quels types de communications (par exemple des ports) sont interdits. Ainsi, de plus petits ensembles correspondent à des pare-feux “plus faibles”, et le *pare-feu vide* ne bloque aucune communication.

On remarque que, dans notre modèle POMDP, nous ne prévoyons pas l’escalade de privilège ou l’obtention de mots de passe. Cela peut à la place être modélisé au niveau de  $LN$ . Différents niveaux de privilèges sur la même machine  $m$  peuvent être encodés à l’aide de différentes copies de  $m$ . Si le contrôle de  $m$  permet la récupération de mots de passe, alors  $m$  peut être connectée à l’aide de pare-feux vides aux machines  $m'$  qui peuvent être atteintes en utilisant ces mots de passe, ou plus précisément à des copies à haut-privilèges de ces  $m'$ .

## 2.2 Les tests de pénétration

L’incertitude dans le pentesting apparaît parce qu’il est impossible de garder trace de tous les détails de *configuration* des machines individuelles, c’est-à-dire des versions exactes des programmes installés, etc. Toutefois, on peut sans risque faire l’hypothèse que l’outil de pentesting connaît la structure du réseau, c’est-à-dire le graphe  $LN$  et le filtrage effectué par chaque pare-feu : les changements à ce niveau sont peu fréquents et peuvent être facilement enregistrés.

L’objectif du pentesting est de prendre contrôle de certaines machines (au contenu critique) du réseau. A n’importe qu’elle moment, chaque machine a un *statut* unique. Une machine *contrôlée*  $m$  a déjà été piratée. Une machine *atteinte*  $m$  est connectée à une machine contrôlée, c’est-à-dire que soit  $m$  est dans un sous-réseau  $N$  dont une machine est contrôlée, soit  $m$  est dans un sous-réseau  $N'$  avec un arc de  $LN$ ,  $N \xrightarrow{F} N'$ , tel que l’une des machines de  $N$  est contrôlée. Toutes les autres machines sont *non atteintes*. L’algorithme commence avec une machine contrôlée, dénotée ici par  $*$ .<sup>1</sup> Nous utiliserons la situation suivante (petite mais réaliste) comme exemple dans la suite de cet article.

### Exemple 1

L’attaquant a déjà piraté une machine  $m'$ , et souhaite maintenant attaquer une machine  $m$  dans le même sous-réseau. L’attaquant connaît deux exploits : SA, l’exploit “Symantec Rtvscan buffer overflow”; et CAU, l’exploit “CA Unicenter message queuing”. SA cible une version particulière de “Symantec Anti-virus”, lequel écoute usuellement le port 2967. CAU cible une version particulière de “CA Unicenter”, qui écoute usuellement sur le port 6668. Les deux fonctionnent seulement si un mécanisme de protection appelé DEP (“Data Execution Prevention”) est désactivé.

Si SA échoue, alors il est probable que CAU échouera aussi (parce que DEP est activé). L’attaquant ferait alors mieux d’essayer autre chose. Atteindre un tel comportement requiert que le plan d’attaque observe les résultats des actions, et réagisse en conséquence. La planification classique (qui suppose une connaissance parfaite du monde au moment de la planification) ne peut accomplir cela.

En outre, les scans de ports – des actions d’observation testant si un port particulier est ouvert ou non – devraient être utilisés seulement si l’on a réellement l’intention d’exécuter un exploit en rapport. Ici, si nous commençons avec SA, nous devrions scanner seulement le port 2967. Nous pouvons obtenir un tel comportement à travers l’utilisation de POMDP. En revanche, pour réduire l’incertitude, la planification classique requiert un pré-traitement exécutant *tous* les scans possibles. Dans cet exemple, il n’y en a que deux – les ports 2967 et 6668 – mais en général il y en a un grand nombre, ce qui provoque un important trafic réseau et un important temps d’attente.

## 2.3 Les POMDP

Les processus décisionnels de Markov partiellement observables (POMDP) sont usuellement définis (Mohan, 1982; Kaelbling *et al.*, 1998) par un uplet  $\langle \mathcal{S}, \mathcal{A}, \mathcal{O}, T, O, r, b_0 \rangle$ . Si le système est dans un état  $s \in \mathcal{S}$  (l’*espace d’état*), et l’agent effectue une action  $a \in \mathcal{A}$  (l’*espace d’action*), alors en résulte (1) une transition

1. Par simplicité, nous dénoterons  $*$  comme un nœud séparé de  $LN$ . Si  $*$  fait partie du sous-réseau  $N$ , cela implique de transformer  $N \setminus \{*\}$  en un nœud séparé de  $LN$ , connecté à  $*$  à l’aide d’un pare-feu vide.

vers un état  $s'$  selon la *fonction de transition*  $T(s, a, s') = Pr(s'|s, a)$ , (2) une observation  $o \in \mathcal{O}$  (l'espace d'observation) selon la *fonction d'observation*  $O(s', a, o) = Pr(o|s', a)$  et (3) une *récompense* scalaire  $r(s, a, s')$ .  $b_0$ , la *croissance initiale*, est une distribution de probabilité sur  $\mathcal{S}$ .

L'agent doit trouver une *politique* de décision  $\pi$  choisissant, à chaque étape, la meilleure action en fonction de ses observations passées et des actions de manière à maximiser ses gains futurs, lesquels nous mesurons ici à travers le total des récompenses accumulées. La valeur espérée d'une politique optimale est dénotée  $V^*$ .

L'agent raisonne typiquement sur l'état caché du système en utilisant un *état de croyance*  $b$ , une distribution de probabilité sur  $\mathcal{S}$ . Pour nos expérimentations nous utilisons SARSOP (Kurniawati *et al.*, 2008), un algorithme à base de points de l'état de l'art, c'est-à-dire un algorithme approchant la fonction de valeur comme l'enveloppe supérieure d'un ensemble d'hyperplans, lesquels correspondent à une sélection d'états de croyance particuliers (appelés "points").

### 3 Modèle POMDP

Une version préliminaire de notre modèle POMDP a été présentée dans le workshop SecArt'11 (Sarraute *et al.*, 2011a). Le lecteur peut se référer à cet article pour un exemple plus détaillé listant des modèles de transition et d'observation complets pour certaines actions, et illustrant l'évolution des états de croyance quand ces actions sont appliquées. Dans ce qui suit, nous gardons des descriptions brèves par soucis de gain d'espace.

#### 3.1 États

Plusieurs aspects du problème – notamment la structure du réseau et les règles de filtrage des pare-feux – sont connus et statiques. Les variables encodant ces aspects peuvent être éliminées lors d'un pré-traitement, et ne sont pas incluses dans notre modèle.

Les états saisissent le statut de chaque machine (contrôlée/atteinte/non atteinte). Pour les machines non contrôlées, ils spécifient aussi la configuration logicielle (système d'exploitation, serveurs, ports ouverts, ...). Nous spécifions les programmes vulnérables, ainsi que les programmes qui peuvent fournir de l'information à propos de ceux-ci (par exemple, le mécanisme de protection "DEP" de notre exemple est pertinent pour les deux exploits). Les états indiquent aussi si une machine ou un programme donné a planté.

Finalement, nous introduisons un état spécial, *terminal*, dans le modèle POMDP (de l'ensemble du réseau, pas des machines individuelles). Cet état correspond à l'abandon de l'attaque, quand, pour chaque action disponible (s'il en reste), le bénéfice potentiel ne compense pas les coûts d'action.

#### Exemple 2

Les états décrivent la machine attaquée  $m$ . Pour simplifier, nous ferons l'hypothèse que les exploits ne risquent pas ici de planter la machine (voir aussi la sous-section suivante). À part l'état terminal et l'état représentant le fait que  $m$  est contrôlée, les états spécifient quels programmes ("SA" ou "CAU") sont présents, s'ils sont vulnérables, et si "DEP" est activé. Chaque application écoute sur un port différent, donc un port est ouvert ssi l'application associée est présente, et nous n'avons pas besoin de modéliser les ports séparément. Nous avons ainsi un total de 20 états :

1 terminal	3 m_none	12 m_DEP_none
2 m_controlled	4 m_CAU	13 m_DEP_CAU
	5 m_CAU_Vul	14 m_DEP_CAU_Vul
	6 m_SA	15 m_DEP_SA
	7 m_SA_CAU	16 m_DEP_SA_CAU
	8 m_SA_CAU_Vul	17 m_DEP_SA_CAU_Vul
	9 m_SA_Vul	18 m_DEP_SA_Vul
	10 m_SA_Vul_CAU	19 m_DEP_SA_Vul_CAU
	11 m_SA_Vul_CAU_Vul	20 m_DEP_SA_Vul_CAU_Vul

En résumé, les états de chaque machine  $m$  sont essentiellement des uplets de valeurs de statuts pour chaque programme pertinent. Les états du système global sont alors des uplets des ces états de machines, avec une entrée pour chaque  $m \in M$ . L'espace d'état énumère ces uplets. Dit autrement, l'espace d'état est factorisé d'une façon naturelle, par programmes et par machines. Une option évidente est donc de modéliser

et résoudre le problème en utilisant des POMDP factorisés (Hansen & Feng, 2000). Nous n'avons pas encore essayé cela ; notre générateur de modèle POMDP énumère les états en interne et fournit ce modèle à SARSOP.<sup>2</sup>

La nature factorisée de notre problème implique aussi que l'espace d'état est énorme. Dans un cadre réaliste, l'ensemble  $C$  des uplets de configurations possibles pour chaque machine  $m \in M$  est très grand, donnant un espace d'état énorme  $|\mathcal{S}| = O(|C|^{|M|})$ . En pratique, nous n'exécuterons des POMDP que sur des machines seules, c'est-à-dire pour  $|M| = 1$ .

### 3.2 Actions

Pour atteindre l'état terminal, nous avons besoin d'une action *terminate* (terminer) indiquant que l'on abandonne l'attaque.

Il y a deux principaux types d'actions, les *scans* et les *exploits*, les deux devant être ciblées vers des machines atteignables. Les scans peuvent être des actions de détection d'OS ou des scans de ports. Dans la plupart des cas, ils n'auront pas d'effet sur l'état de la machine cible. Leur objectif est d'acquérir de la connaissance à propos de la configuration de la machine à l'aide d'une observation qui permet typiquement d'éliminer certains états de la croyance (par exemple, observer que l'OS doit être une certaine version de Windows XP). Les exploits font usage d'une vulnérabilité – si elle est présente – pour prendre le contrôle d'une machine. Le résultat de cet exploit est observé par l'attaquant, de sorte que l'échec d'un exploit peut, comme un scan, donner de l'information à propos de la configuration (par exemple, que le mécanisme de protection est probablement actif). Pour une minorité d'exploits, une tentative ratée plante la machine.

Pour toutes les actions, le résultat est déterministe : quelle observation est retournée, et si un exploit réussit/échoue/plante, est déterminé de manière unique par la configuration de la machine cible.

#### Exemple 3

Dans notre exemple, il y a cinq actions possibles :

```
m_exploit_SA
m_exploit_CAU
m_scan_port_2967
m_scan_port_6668
terminate
```

Le modèle POMDP spécifie, pour chaque état dans l'exemple 2, le résultat de chaque action. Par exemple, *m\_exploit\_SA* réussit si et seulement si SA est présent et vulnérable, et DEP est désactivé. Ainsi, quand appliquée à l'état 9, 10 ou 11, *m\_exploit\_SA* résulte en l'état 2, et retourne l'observation *succeeded*. Appliquée à n'importe quel autre état, *m\_exploit\_SA* laisse l'état inchangé, et l'observation est *failed*.

Les résultats des actions dépendent aussi du pare-feu (s'il y en a un) érigé entre le pentesteur et la cible. Si le pare-feu filtre le port associé à une action, alors celle-ci est inutilisable : son modèle de transition laisse l'état inchangé, et aucune observation n'est retournée. Par exemple, si le pare-feu  $F$  filtre le port 2967, alors *m\_scan\_port\_2967* et *m\_exploit\_SA* sont inutilisables à travers  $F$ , mais peuvent être employées dès qu'une machine derrière  $F$  est sous contrôle.

### 3.3 Récompenses

Aucune récompense n'est obtenue quand on utilise l'action *terminate* ou dans l'état terminal.

La récompense instantanée pour n'importe quelle action scan/exploit dépend de la transition qu'elle entraîne depuis l'état courant. Notre modèle simple est de décomposer additivement la récompense instantanée  $r(s, a, s')$  en  $r(s, a, s') = r_e(s, a, s') + r_t(a) + r_d(a)$ . Ici, (i)  $r_e(s, a, s')$  est la valeur de la machine attaquée dans le cas où la transition  $(s, a, s')$  correspond à un exploit réussi, et vaut 0 pour toute autre transition ; (ii)  $r_t(a)$  est un coût qui dépend de la durée de l'action ; et (iii)  $r_d(a)$  est un coût qui reflète le risque de détection quand on utilise cette action. (iii) est orthogonal au risque de planter un programme ou une machine, ce que, comme décrit, nous modélisons comme un possible résultat d'exploits. Notons que (ii) et (iii) peuvent être corrélés ; toutefois, il n'y a pas bijection entre durée et risque de détection d'un exploit, il est

2. Notons que cette approche permet certaines optimisations non-triviales : certains des états dans l'exemple 2 pourraient être fusionnés. Si DEP est activé, alors il importe peu que CAU/SA soient vulnérables. Par souci de brièveté, nous ne discutons pas ici ce point en détail.




FIGURE 1 – Les trois chaînes de Markov indépendantes utilisées pour modéliser le mécanisme de mise à jour de notre réseau exemple.

donc pertinent d'être capable de distinguer les deux. Finalement, notons que (i) résulte de la somme des récompenses pour les exploits réussis sur différentes machines. Ce n'est pas une hypothèse contraignante : on peut récompenser le fait de pénétrer dans  $[m_1 \text{ OU } m_2]$  en introduisant une nouvelle machine virtuelle, accessible sans coût depuis aussi bien  $m_1$  que  $m_2$ .

#### Exemple 4

Dans notre exemple, nous fixons  $r_e = 1000$  en cas de succès, 0 sinon ;  $r_t = -10$  pour toutes les actions ; and  $r_d = 0$  (aucun risque de détection). Nous verrons ci-dessous quel effet ces réglages ont sur une politique optimale.

Puisque toutes les actions sont déterministes, il n'est pas utile de les répéter sur la même cible à travers le même pare-feu – cela ne produira pas de nouveaux effets ou n'apportera pas de nouvelles informations. En particulier, les récompenses positives ne peuvent être reçues plusieurs fois. Ainsi, des comportements cycliques encourent des coûts négatifs infinis. Cela implique que le retour espéré d'une politique optimale est fini même sans facteur d'atténuation.<sup>3</sup>

### 3.4 Concevoir la croyance initiale

Un test de pénétration est effectué à intervalles de temps réguliers. La croyance initiale – notre connaissance du réseau quand on commence le pentest – dépend de (a) ce qui était connu à la fin du pentest précédent, et de (b) ce qui peut avoir changé depuis. Nous faisons l'hypothèse pour des raisons de simplicité que la connaissance (a) est parfaite, c'est-à-dire qu'une configuration concrète  $I(m)$  est affectée à chaque machine  $m$  au temps 0 (du dernier pentest). Nous calculons alors la croyance initiale comme une fonction  $b_0(I, T)$  où  $T$  est le nombre de jours passés depuis le dernier pentest. L'incertitude dans cette croyance vient de ne pas savoir quelles mises à jour logicielles ont été appliquées. Nous faisons l'hypothèse que les mises à jour sont effectuées indépendamment sur chaque machine (hypothèse simplificatrice, mais raisonnable étant donné que les mises à jour sont contrôlées par des utilisateurs individuels).

Un modèle simple de mises à jour (Sarraute *et al.*, 2011a) encode l'évolution incertaine de chaque programme indépendamment au moyen d'une chaîne de Markov. Les états de chaque chaîne correspondent aux différentes versions du programme, et les transitions modélisent les mises à jour possibles du programme (avec des probabilités estimées que ces mises à jour auront lieu). La croyance initiale est alors la distribution résultant de cette chaîne après  $T$  pas de temps.

#### Exemple 5

Dans notre exemple, les trois composants de l'unique machine sont DEP, CAU et SA. Ils sont mis à jour à l'aide de trois chaînes de Markov indépendantes, chacune avec deux états, comme illustré sur la figure 1. Les probabilités indiquent quelles sont les chances que la machine passe d'un état à un autre pendant un jour. Disons que l'on fixe  $T = 30$ , et lançons les chaînes de Markov sur la configuration  $I$  dans laquelle  $m$  a le DEP désactivé, et SA et CAU sont tous deux vulnérables aux exploits de l'attaquant. Dans la croyance initiale résultante  $b_0(I, T)$ , DEP a des chances d'être activé ; le poids des états 12–20 dans l'exemple 2 est élevé dans  $b_0$  ( $> 70\%$ ).

Ici, nous utilisons ce modèle simple comme bloc de construction élémentaire dans une méthode prenant en compte que la version  $x$  du programme A peut nécessiter la version  $y$  ou  $z$  du programme B. Nous faisons l'hypothèse que les programmes sont organisés d'une manière hiérarchique, le système d'exploitation

3. En fait, le problème tombe dans la classe des *problèmes de chemin stochastique le plus court* (Bertsekas & Tsitsiklis, 1996).




FIGURE 2 – Illustration des niveaux 1, 2 et 3 (de gauche à droite) de l'algorithme 4AL.

étant à la racine d'un graphe orienté acyclique, et un programme ayant comme parents les programmes dont il dépend directement. Cela donne un réseau bayésien dynamique, dans lequel chaque distribution de probabilité conditionnelle est dérivé d'une chaîne de Markov  $Pr(X_t = x' | X_{t-1} = x)$  filtrée par une fonction de compatibilité  $\delta(X = x, parent_1(X) = x_1, \dots, parent_k(X) = x_k)$ , qui retourne 1 ssi la valeur de  $X$  est compatible avec les versions des parents, 0 sinon. Ce modèle de mises à jour est raisonnable, mais évidemment pas encore réaliste ; les travaux futurs devront étudier de tels modèles en détail.

Nous illustrons maintenant comment le fait de raisonner avec les probabilités de la croyance initiale permet d'obtenir le comportement intelligent désiré.

### Exemple 6

Supposons que nous calculons la croyance initiale  $b_0(I, T)$  comme dans l'exemple 5. Puisque le poids des états 12–20 est élevé dans  $b_0$ , si  $m\_exploit\_SA$  échoue, alors la probabilité de succès de  $m\_exploit\_CAU$  est réduite au point de ne plus valoir d'efforts, et que l'attaquant (une politique optimale) abandonne, c'est-à-dire qu'elle essaye une attaque différente non entravée par le DEP. Plus précisément, considérons  $Pr(CAU^+ | 2967^+)$ , c'est-à-dire la probabilité que  $m\_exploit\_CAU$  réussisse, après avoir observé que le port 2967 est ouvert. Cela correspond au poids (A) des états 8 et 11 dans l'exemple 2, par rapport aux états (B) 6–11 plus 15–20. Ce poids (A/B) est à peu près 20%. Ainsi la valeur espérée de  $m\_exploit\_CAU$  dans cette situation est à peu près  $100 * 0,2$  [récompense de succès]  $- 10$  [coût d'action] = 10, cf. exemple 4, de sorte que l'action en vaut la peine. A l'inverse, supposons que  $m\_exploit\_SA$  a déjà été essayée et a échoué. Alors (A) est réduit à l'état 8 seul, alors que (B) contient toujours (en particulier) tous les états DEP 15–20. Ces derniers états ont un poids important, et donc  $Pr(CAU^+ | 2967^+, SA^-)$  n'est que d'environ 5%. Compte tenu de cela, la valeur espérée de  $m\_exploit\_CAU$  est négative, et il est préférable d'appliquer terminate à la place.



**Algorithm 1:** Level 1 (Decomposing the Network)

---

**Input:**  $LN$  : Logical Network.  
**Output:** Approximation  $V$  of expected value  $V^*$  of attacking  $LN$  from controlled machine  $*$ .

```

/* Decompose  $LN$  into tree  $DLN$  of
   biconnected components, rooted at  $*$ ; see
   text for "clean-up". */
1  $DLN \leftarrow \text{HopcroftTarjan}(LN)$ ;
2 Set tree root to  $*$  and clean-up  $LN$  and  $DLN$ ;
3  $C_1, \dots, C_k \leftarrow$  a topological ordering of  $DLN$ ;
4 Initialize pivoting reward  $pr(N)$  for all
    $N \in LN$  to 0;
5 for  $i = k, \dots, 1$  do
   | /* Call Level 2 to attack each component.
   | */
   |  $V(C_i) \leftarrow \text{Level2}(C_i, pr)$ ;
   | /* Propagate expected reward. */
   |  $N \leftarrow$  the parent of  $C_i$  in  $LN$ ;
   |  $pr(N) \leftarrow pr(N) + V(C_i)$ ;
9 return  $pr(*)$ 

```

---

**Algorithm 3:** Level 3 (Attacking Subnetworks)

**Input:** Firewall  $F$ , subnetwork  $N$ , rewards  $pR$ ,  $pathR$ .  
**Output:** Approximation  $V$  of expected value  $V^*$  of attacking  $N$  through  $F$ , given  $F$  is reached,  $N$ 's pivoting reward is  $pR$ , and the path reward behind  $N$  is  $pathR$ .

```

1  $R \leftarrow 0$ ;
   /* Maximize over reward obtained when hacking
   first into a particular machine  $m \in N$ . */
2 foreach  $m \in N$  do
3    $R(m) \leftarrow r(m)$ ;
   /* After breaking  $m$ , we can pivot behind
    $N$ , and reach all  $m \neq m' \in N$  without
    $F$ . */
4    $R(m) \leftarrow R(m) + pR + pathR$ ;
5   foreach  $m \neq m' \in N$  do
6      $R(m) \leftarrow R(m) + \text{Level4}(m', \emptyset, r(m'))$ ;
7    $R \leftarrow \max(R, \text{Level4}(m, F, R(m)))$ ;
8 return  $R$ 

```

---

**Algorithm 2:** Level 2 (Attacking Components)

**Input:** Biconnected component  $C$ , reward function  $pr$ .  
**Output:** Approximation  $V$  of expected value  $V^*$  of attacking  $C$ , given its parent is controlled and its pivoting rewards are  $pr$ .

```

1  $R \leftarrow 0$ ;
   /* Account for each rewarded vertex  $N$ . */
2 while  $\exists N \in C$  s.t.  $r(N) > 0$  or  $pr(N) > 0$  do
3    $P \leftarrow \langle \rangle$ ;  $R(P) \leftarrow 0$ ;  $P(N) \leftarrow P$ ;
   /* Maximize over all simple paths (no
   repeated vertices) from an entry
   vertex to  $N$ . */
4   foreach simple path  $P$  of the form
      $F_0 \rightarrow N_1 \xrightarrow{F_1} N_2 \dots \xrightarrow{F_{k-1}} N_k = N$  where
      $N_1, \dots, N_k \in C$  and  $N_1 \in C_*$  do
     | /* Propagate rewards along  $P$ , calling
     | Level 3 for attack on each
     | subnetwork. */
     |  $R(P) \leftarrow 0$ ;
     | for  $i = k, \dots, 1$  do
     | |  $R(P) \leftarrow$ 
     | |  $\text{Level3}(N_i, F_{i-1}, pr(N_i), R(P))$ ;
     |  $P(N) \leftarrow \arg \max(R(P(N)), R(P))$ ;
9    $R \leftarrow R + R(P(N))$ ;
10   $r(N_i), pr(N_i) \leftarrow 0$  for all vertices  $N_i$  on
     $P(N)$ ;
11 return  $R$ 

```

---

**Algorithm 4:** Level 4 (Attacking Individual Machines)

**Input:** Firewall  $F$ , machine  $m$ , reward  $R$ .  
**Output:** Approximation  $V$  of expected value  $V^*$  of attacking  $m$  through  $F$ , given  $m$  is reached and the current reward of breaking it is  $R$ .

```

1 if  $(m, F, R)$  is cached then
2   return  $V(m, F, R)$ 
3  $M \leftarrow \text{createPOMDP}(m, F, R)$ ;
4  $V \leftarrow \text{solvePOMDP}(M)$ ;
5 Cache  $(m, F, R)$  with  $V$ ;
6 return  $V$ 

```

---

## 4 L'algorithme de décomposition 4AL

Comme évoqué, les POMDP ne passent pas à l'échelle pour de grands réseaux (cf. les expérimentations dans la section suivante). Nous présentons maintenant une approche utilisant décomposition et approximation pour surmonter ce problème, reposant sur les POMDP seulement pour attaquer des machines individuelles. L'approche est appelée 4AL parce qu'elle s'attache à l'attaque d'un réseau à 4 niveaux d'abstraction différents (4 *abstraction levels*). 4AL est un résolveur de POMDP spécialisé dans la planification d'attaques

telle que considérée ici. Son entrée est un réseau logique  $LN$  et des modèles POMDP encodant les attaques de machines individuelles. Sa sortie est une politique (une attaque) pour le POMDP global encodant  $LN$ , de même qu’une approximation de la fonction de valeur globale. Nous donnons dans la suite un aperçu de l’algorithme, puis précisons les détails techniques. Pour simplifier la présentation, nous nous concentrons sur l’approximation de la fonction de valeur, et décrivons seulement brièvement comment construire la politique.

#### 4.1 Aperçu de 4AL et propriétés élémentaires

Les quatre niveaux de 4AL sont : (1) *décomposer le réseau*, (2) *attaquer les composants*, (3) *attaquer les sous-réseaux*, et (4) *attaquer les machines individuelles*. Nous décrivons les niveaux tour à tour avant de fournir des détails techniques. La figure 2 fournit des illustrations.

- **Niveau 1** : Décompose le réseau logique  $LN$  en un arbre de composants bi-connectés, enraciné en  $*$ . Dans l’ordre topologique inverse, appeler le niveau 2 sur chaque composant ; propager les résultats vers le haut dans l’arbre.

Chaque graphe se décompose en un unique arbre de composants bi-connectés (Hopcroft & Tarjan, 1973). Un composant bi-connecté est un sous-graphe qui reste connecté quand on retire n’importe quel arc. Dans le pentesting, cela signifie intuitivement qu’il y a plus qu’une façon (plus d’un chemin) pour attaquer les sous-réseaux de ce composant, ce qui nécessite de raisonner à propos du composant comme un tout (ce qui est le travail du niveau 2). Au contraire, si retirer le sous-réseau  $X$  (par exemple,  $N_2$  dans la figure 2 (b)) fait que le graphe est coupé en deux morceaux ( $C_2$  vs. le reste de  $LN$ , voir aussi la figure 2 (a)), alors *toutes* les attaques de  $*$  vers l’un de ces sous-graphes (ici  $C_2$ ) doit d’abord traverser  $X$  (ici  $N_2$ ). Ainsi la valeur espérée totale de l’attaque peut être calculée par (1) le calcul la valeur d’une attaque de ce sous-graphe ( $C_2$ ) seul, et (2) l’ajout de ce résultat comme une *récompense de pivotement* pour récompenser la prise de contrôle de  $X$  ( $N_2$ ). Dit autrement, nous “propageons les résultats vers le haut” dans l’arbre représenté dans la figure 2 (a).

Il est important de noter que cette décomposition arborescente résultera typiquement en une énorme réduction de complexité. Les composants bi-connectés dans  $LN$  ne proviennent que de clusters de plus de 2 sous-réseaux partageant une même machine pare-feu (physique). De tels clusters tendent à être petits. Dans le scénario de test réaliste utilisé par Core Security et ici dans nos expérimentations, il n’y a qu’un seul cluster, de taille 3. S’il n’y a pas de cluster du tout,  $LN$  est un arbre et le niveau 2 de 4AL devient complètement trivial.

- **Niveau 2** : Etant donné le composant  $C$ , considérons, pour chaque sous-réseau récompensé  $N \in C$ , tous les chemins  $P$  dans  $C$  qui atteint  $N$ . En remontant chaque  $P$  en arrière, appeler le niveau 3 sur chaque sous-réseau avec chaque pare-feu associé. Choisir le meilleur chemin pour chaque  $N$ . Agréger les valeurs de ces chemins sur tout  $N$ , en additionnant mais en ignorant les récompenses qui ont déjà été prises en compte par un chemin précédent dans la somme.

Dans le cas où un composant bi-connecté  $C$  contient plus d’un sous-réseau, pour obtenir la meilleure attaque de  $C$ , en général nous n’avons d’autre choix que d’encoder le composant entier comme un POMDP. Puisque ce n’est pas faisable, le niveau 2 considère des “chemins d’attaque” individuels à l’intérieur de  $C$ . N’importe quel chemin  $P$  est équivalent à une séquence d’attaques sur des sous-réseaux individuels ; ces attaques sont évaluées en utilisant le niveau 3. Nous considérons les nœuds récompensés  $N$  séparément, en énumérant les chemins d’attaque et en choisissant le meilleur. Les valeurs des meilleurs chemins sont agrégées sur tout  $N$  d’une manière conservatrice (pessimiste), en tenant compte de chaque récompense au plus une fois. Une sous-estimation stricte a lieu dans le cas où les meilleurs chemins pour certains nœuds récompensés ne sont pas disjoints : alors ces attaques partagent une partie de leur coût, de sorte qu’une attaque combinée a une récompense espérée plus élevée que la somme des attaques indépendantes.

Dans la figure 2 (b),  $N_2$  et  $N_3$  ont une récompense de pivotement parce qu’ils permettent d’atteindre les composants  $C_2$  et  $C_3$  respectivement. Si les meilleurs chemins pour à la fois  $N_2$  et  $N_3$  passent par  $N_1$  (parce que le pare-feu  $F_3^*$  est très strict), alors ces chemins ne sont pas disjoints, dupliquant l’effort pour pénétrer dans  $N_1$ .

Évidemment, énumérer les chemins d’attaque dans  $C$  est exponentiel en la taille de  $C$ . C’est le seul point dans 4AL – à part évidemment les appels au solveur de POMDP – qui a un temps d’exécution exponentiel dans le pire cas. En pratique, les composants bi-connectés sont typiquement petits, cf. ci-dessus.

- **Niveau 3** : Etant donné un sous-réseau  $N$  et un pare-feu  $F$  à travers lequel attaquer  $N$ , pour chaque machine  $m \in N$ , approximer la récompense obtenue en attaquant  $m$  d’abord. Pour cela, modifier

la récompense de  $m$  pour tenir compte du fait que, après avoir pénétré  $m$ , nous serons derrière  $F$  : appeler le niveau 4 pour obtenir les valeurs de tous les  $m' \neq m$  avec un pare-feu vide ; ajouter ensuite ces valeurs, plus toute récompense de pivotement, à la récompense de  $m$  et appeler le niveau 4 sur ce  $m$  modifié avec le pare-feu  $F$ . Maximiser la valeur résultante sur tous les  $m \in N$ .

Considérons la figure 2 (c). Quand on attaque  $N$  (ici,  $N_3$ ) depuis une machine derrière  $F$  (ici,  $F_3^1$ ), nous avons à choisir quelle machine dans  $N$  attaquer. Etant donné qu'on s'engage sur un tel choix  $m$ , le problème de l'attaque devient celui de pénétrer dans  $m$  et après cela d'exploiter la connexion directe vers n'importe quel  $m \neq m' \in N$ , et n'importe quel réseau descendant (ici,  $C_3$ ) vers lequel on peut pivoter. Comme décrit, on peut traiter cela en combinant des attaques sur des machines individuelles avec des récompenses modifiées. (La récompense de pivotement pour les réseaux descendants est calculée au préalable par les niveaux 1 et 2.)

Comme le niveau 2, le niveau 3 fait des approximations conservatives. Il fixe un choix du  $m \in N$  à attaquer. Au contraire, la meilleure stratégie peut consister à basculer entre différents  $m \in N$  selon le succès de l'attaque jusqu'ici. Par exemple, si un exploit a de grandes chances de réussir, alors il peut être payant de l'essayer d'abord sur tous les  $m$ , avant d'essayer quoi que ce soit d'autre.

- **Niveau 4** : Etant donnée une machine  $m$  et un pare-feu  $F$ , modéliser le problème de planification d'attaques pour une seule machine comme un POMDP, et lancer un résolveur prêt-à-l'emploi. Mettre en cache les résultats obtenus pour éviter les doubles emplois.

Cette dernière étape ne devrait pas avoir besoin d'explications. Le modèle POMDP est créé comme décrit précédemment. Notons que le niveau 3 peut, durant l'exécution de 4AL, appeler la même machine avec le même pare-feu plus d'une fois. Par exemple, dans la figure 2 (c), quand on bascule vers l'attaque de  $m'_1$  au lieu de  $m$ , l'appel du niveau 4 avec  $m'_k$  et un pare-feu vide est répété.

Pour résumer, 4AL a un temps de calcul bas polynomial sauf pour l'énumération de chemins dans les composants bi-connectés (niveau 2), et résoudre des POMDP pour une seule machine (niveau 4). La décomposition au niveau 1 ne subit aucune perte d'information. Les niveaux 2 et 3 font des approximations conservatives, de sorte que, si les solutions des POMDP sont conservatives (par exemple, optimales), alors le résultat d'ensemble de 4AL est aussi conservatif.

## 4.2 Détails techniques

Pour fournir une compréhension plus détaillée de 4AL, nous discutons maintenant du pseudo-code de l'algorithme, fourni dans la figure 4. Considérons d'abord l'algorithme 1. Il devrait être clair comment la structure d'ensemble de l'algorithme correspond à notre discussion précédente. Il appelle l'algorithme à temps linéaire de Hopcroft & Tarjan (1973) (par la suite, HT) pour trouver la décomposition. La boucle  $i = k, \dots, 1$  traite les composants dans l'ordre topologique inverse. La fonction de récompense de pivotement  $pr$  encode la propagation de récompenses vers le haut de l'arbre ; cela ne devrait pas avoir besoin d'explications, à part pour l'expression "le parent" de  $C_i$  dans  $LN$ . Cette dernière repose sur le fait que, après nettoyage ("clean-up", ligne 2), chaque composant a exactement un tel parent.

Pour expliquer le nettoyage, notons d'abord que HT travaille sur des graphes non-orientés ; quand nous l'appliquons, nous ignorons la direction des arcs dans  $LN$ . Le résultat est un arbre non-orienté de composants bi-connectés, où les *nœuds-coupes* – les nœuds dont la suppression coupe le graphe en morceaux – sont partagés entre plusieurs composants. Dans la figure 2 (b), par exemple,  $N_2$ , avant nettoyage, appartient à la fois à  $C_1$  et  $C_2$ . Le nettoyage fixe la racine de l'arbre à  $*$ , et affecte chaque nœud-coupe au composant le plus proche de  $*$  (par exemple,  $N_2$  est affecté à  $C_1$ ) ;  $*$  lui-même est transformé en un composant séparé. En ré-introduisant l'orientation des arcs dans  $LN$ , nous éliminons alors les nœuds non accessibles depuis  $*$ . Ensuite, nous retirons les arcs qui ne peuvent pas participer à des chemins d'attaque non redondants partant de  $*$ . Puisqu'aller *vers*  $*$  dans la décomposition arborescente ramène nécessairement toute attaque vers un nœud qu'elle a déjà visité (pénétré), après une telle suppression les arcs entre les composants forment un arbre orienté comme sur la figure 2 (a). Chaque composant non-racine  $C_i$  (par exemple  $C_3$ ) a exactement un parent composant  $C$  dans l'arbre nettoyé (par exemple  $C_1$ ). Le sous-réseau respectif  $N \in C$  (par exemple  $N_3$ ) est un nœud-coupe de  $LN$ . Ainsi, comme affirmé plus haut,  $N$  est le *seul* nœud, dans  $LN$ , connecté à  $C_i$ .

De manière évidente, toutes les attaques sur  $C_i$  doivent passer à travers son parent  $N$ . De plus, les nœuds et arcs supprimés par nettoyage ne peuvent pas faire partie d'une attaque optimale. Ainsi le niveau 1 est sans perte. Pour exprimer cela – et les autres propriétés de 4AL – formellement, nous avons besoin de quelques notations. nous utiliserons  $V^*$  pour désigner la valeur espérée réelle (optimale) d'une attaque, et  $V$  pour

désigner l'approximation 4AL. L'objet attaqué est donné en argument. Par exemple,  $V^*(LN)$  est la valeur espérée pour attaquer  $LN$ ;  $V(C, pr)$  est le résultat de l'exécution de 4AL niveau 2 sur le composant  $C$  et la fonction de récompense de pivotement  $pr$ .

**Proposition 1**

Soit  $LN$  un réseau logique. Supposons que, pour tous les appels à 4AL niveau 2 effectués par 4AL niveau 1 quand lancé sur  $LN$ , nous avons  $V(C, pr) = V^*(C, pr)$ . Alors  $V(LN) = V^*(LN)$ . Si  $V(C, pr) \leq V^*(C, pr)$  pour tous les appels à 4AL niveau 2, alors  $V(LN) \leq V^*(LN)$ .

Considérons maintenant l'algorithme 2. Notre description précédent était imprécise en omettant l'argument additionnel de l'algorithme  $pr$ . Celui-ci s'intègre à l'algorithme en étant passé, pour chaque sous-réseau sur les chemins que nous considérons (ligne 7), à l'algorithme 3 l'ajoute à la récompense obtenue pour avoir pénétré dans ce sous-réseau (algorithm 3 ligne 4).

$R$  agrège les valeurs (lignes 1, 9) sur tous les sous-réseaux récompenses  $N$ . Cette agrégation est rendue conservative en enlevant toutes les récompenses – les récompenses de pivotement aussi bien que les récompenses propres des machines individuelles impliquées – qui ont déjà été prise en compte (ligne 10). En ce qui concerne les machines individuelles, l'algorithme 2 utilise pour faire plus court (a)  $r(N) > 0$  (ligne 2) et (b)  $r(N) \leftarrow 0$  (ligne 10); (a) signifie qu'il existe  $m \in N$  tel que  $r(m) > 0$ ; (b) signifie que  $r(m) \leftarrow 0$  pour tout  $m \in N$ . En ce qui concerne les récompenses de pivotement, notons que la ligne 10 de l'algorithme 2 modifie la fonction  $pr$  maintenue par l'algorithme 1. Cela ne créé pas de conflits puisque, quand l'algorithme 1 appelle l'algorithme 2 sur le composant  $C$ , tous les descendants de  $C$  dans  $LN$  ont déjà été traités, et donc en particulier l'algorithme 1 ne fera plus des mises à jour de la valeur de  $pr(N)$ , quelque soit  $N \in C$ .

Par  $C_*$  (ligne 4) nous désignons l'ensemble  $\{N \in C \mid \exists N' \in LN, N' \notin C : (N', N) \in LN\}$  de sous-réseaux qui servent d'entrée dans  $C$  (par exemple,  $N_1$  et  $N_3$  pour  $C_1$  dans la figure 2 (b)). Notons à la ligne 4 que le chemin  $P$  commence avec un pare-feu  $F_0$ . Pour comprendre cela, observons la situation considérée. L'algorithme suppose que le parent  $N$  de  $C$  (\*, pour le composant  $C_1$  dans la figure 2 (b)) est sous contrôle. Mais alors, pour pénétrer  $C$ , nous avons encore besoin de traverser un arc de  $N$  vers  $C$ .  $F_0$  est le pare-feu sur l'arc choisi par  $P$  ( $F_1^*$  ou  $F_3^*$  dans la figure 2 (b)).

Les appels au niveau 3 (ligne 7) comprennent le réseau  $N_i$  dans lequel pénétrer, le pare-feu  $F_{i-1}$  qui doit être traversé pour cela, la récompense de pivotement de  $N_i$ , ainsi que la récompense de chemin actuelle  $R(P)$  qui est rétro-propagée le long du chemin. Clairement, c'est équivalent à la séquence d'attaques requise pour exécuter  $P$  et récolter toutes les récompenses de pivotement associées à une telle attaque. Ainsi, l'agrégation à travers les sous-réseaux  $N$  étant conservative, nous obtenons :

**Proposition 2**

Soit  $C$  un composant bi-connecté, et soit  $pr$  une fonction de récompense de pivotement. Supposons que, pour tout appel à 4AL niveau 3 effectué par 4AL niveau 2 quand exécuté sur  $(C, pr)$ , nous avons

$$V(F, N, pR, pathR) \leq V^*(F, N, pR, pathR).$$

Alors

$$V(C, pr) \leq V^*(C, pr).$$

Les algorithmes 3 et 4 ne devrait pas nécessiter d'explications, étant donnée notre discussion précédente. Notons juste que la récompense de pivotement  $pR$  est représentée par l'arc de  $m$  vers  $C_3$  dans la figure 2 (c), laquelle est prise en compte simplement en l'additionnant à la valeur de  $m$  (algorithme 3 ligne 4). La récompense de chemin  $pathR$  (non illustrée dans la figure 2 (c)) est aussi ajoutée à la valeur de  $m$  (algorithme 3 ligne 4). Maximiser sur les attaques de machines individuelles  $m$  est, de manière évidente, une approximation conservative parce que les stratégies d'attaque sont libres de choisir  $m$ . Ainsi :


**Proposition 3**

Soit  $F$  un pare-feu,  $N$  un sous-réseau,  $pR$  une récompense de pivotement, et  $pathR$  une récompense de chemin. Supposons que, pour tous les appels à 4AL niveau 4 effectués par 4AL niveau 3 quand exécuté sur  $(F, N, pR, pathR)$ , nous avons


$$V(F, m, R) \leq V^*(F, m, R).$$

Alors

$$V(F, N, pR, pathR) \leq V^*(F, N, pR, pathR).$$



(a) Comparaison de la qualité des attaques.



(b) Temps d'exécution de 4AL.

FIGURE 3 – Résultats expérimentaux de 4AL comparé à un modèle POMDP global.

### 4.3 Construction de la politique

Au niveau 1, la politique globale est construite à partir de politique du niveau 2 simplement en suivant la décomposition arborescente : en partant de la racine de l'arbre, on exécute les politiques de niveau 2 pour tous les composants atteints (dans n'importe quel ordre) ; une fois que le piratage d'un composant a réussi, les composants enfants respectifs deviennent atteints. Au niveau 2, c'est-à-dire à l'intérieur d'un composant bi-connecté  $C$ , la politique correspond à l'ensemble des chemins  $P$  considérés par l'algorithme 2. Chaque  $P$  est traité tour à tour. Pour chaque nœud  $N$  de  $P$  (jusqu'à échec à entrer dans ce sous-réseau), nous appelons la politique de niveau 3 correspondante.

Au niveau 3, c'est-à-dire en considérant un seul sous-réseau  $N$ , notre politique attaque simplement la machine  $m \in N$  qui donnait le maximum dans l'algorithme 3. La politique attaque d'abord  $m$  à travers le pare-feu en utilisant la politique de niveau 4 associée. Dans le cas où l'attaque réussit, la politique attaque les machines restantes  $m' \in N$  dans n'importe quel ordre (c'est-à-dire, pour chaque  $m'$ , nous exécutons la politique de niveau 4 associée jusqu'à terminaison). Au niveau 4, la politique est une politique POMDP classique retournée par notre résolveur de POMDP.

## 5 Expérimentations

Nous avons évalué 4AL contre le modèle POMDP "global", encodant le problème de l'attaque tout entier dans un seul POMDP. Les expérimentations sont lancées sur une machine avec un CPU Intel Core2 Duo à 2,2 GHz et avec 3 Go de RAM. L'algorithme 4AL est implémenté en Python. Pour résoudre et évaluer les POMDP générés par le niveau 4, nous utilisons la boîte à outils APPL.<sup>4</sup>

### 5.1 Scénarios de test

Notre scénario de test repose sur la structure de réseau montrée dans la figure 4. L'attaque commence depuis Internet (\* est le nuage dans le coin en haut à gauche). Le réseau consiste en 3 zones – *Exposed*, *Sensitive*, *User* – séparées par des pare-feux. En interne, *Exposed* comme *Sensitive* sont complètement connectées (c'est-à-dire que ces zones sont des sous-réseaux), alors que *User* consiste en un arbre de sous-réseaux séparés par des pare-feux vides. Seules deux machines sont récompensées, une dans *Sensitive* (récompense 9000) et une dans un sous-réseau feuille de *User* (récompense 5000). Le coût des scans de ports et des exploits est de 10, le coût des détections d'OS de 50. Nous permettons de faire croître le nombre de machines  $|M|$  en distribuant, toutes les 40 machines, la première dans *Exposed*, la seconde dans *Sensitive*, et les 38 restantes dans *User*. Les exploits sont pris dans la base de données de Core Security. Le nombre d'exploits  $|E|$  est passé à l'échelle en distribuant ceux-ci sur 13 modèles, et en affectant à chaque machine  $m$  un tel modèle en tant que  $I(m)$  (la configuration à l'instant du dernier pentest). La croyance initiale  $b_0(I, T)$ , où  $T$  est le temps passé depuis le dernier pentest, est alors généré tel que décrit.

4. APPL 0.93 sur <http://bigbird.comp.nus.edu.sg/pmwiki/farm/appl/>




FIGURE 4 – Structure du réseau dans notre jeu de tests.

Les paramètres fixés ici (récompenses, coûts d'action, distribution des machines sur les zones, nombre de modèles) sont estimés à partir de l'expérience pratique de Core Security. La structure du réseau et les exploits sont réalistes, et sont utilisés pour des tests industriels dans cette compagnie. La principale faiblesse du scénario réside dans l'approximation des mises à jour logicielles sous-tendant  $b_0(I, T)$ . Dans l'ensemble, le scénario est encore simplifié, mais est naturel et approche la complexité des tests de pénétration réels.

Par manque d'espace, dans ce qui suit nous faisons passer à l'échelle seulement  $|M|$  et  $|E|$ , en fixant  $T = 50$ . Cette dernière valeur est difficile : le pentesting est typiquement accompli à peu près une fois par mois ; de plus petits  $T$  sont plus faciles à résoudre puisqu'il y a moins d'incertitude.

## 5.2 Perte en approximation

La figure 3 (a) montre la perte relative de qualité quand on exécute 4AL au lieu d'une solution POMDP globale, pour des valeurs de  $|E|$  et  $|M|$  où cette dernière est faisable. Nous montrons  $quality(global-POMDP) - quality(4AL)$  en pourcent de  $quality(global-POMDP)$ . la qualité de la politique est ici estimée en exécutant 2000 simulations. Cette mesure subit une variance, laquelle est presque plus forte que le très petit avantage en qualité de la solution POMDP globale. La perte maximale pour n'importe quelle combinaison de  $|E|$  et  $|M|$  est de 14,1% (pour  $|E| = 7$ ,  $|M| = 6$ ), la perte moyenne sur toutes les combinaisons est de 1,96%. La perte moyenne croît de façon monotone selon  $|M|$ , de -1,14% for  $|M| = 1$  to 4,37% for  $|M| = 6$ . Selon  $|E|$ , le comportement est moins régulier ; la perte moyenne maximale, 5,4%, est obtenue en fixant  $|E| = 5$ .

## 5.3 Passage à l'échelle

La figure 3 (b) montre le temps d'exécution de 4AL quand on passe à de plus grandes valeurs de  $|E|$  et  $|M|$ . Le comportement de passage à l'échelle selon  $|M|$  reflète clairement le fait que 4AL est polynomial en ce paramètre, sauf pour la taille des composants bi-connectés (ici 4). Faire croître  $E$  donne des POMDP mono-machines plus difficiles, résultant parfois en une croissance forte du temps de calcul. Pourtant, même avec  $|M|$  et  $|E|$  tous deux proches de 100, ce qui est une taille réaliste en pratique, le temps d'exécution est toujours sous les 37 secondes.

## 6 Conclusion

Nous avons conçu un modèle POMDP pour les tests de pénétration qui permettent de représenter naturellement beaucoup des caractéristiques de cette application, en particulier la connaissance incomplète de la configuration du réseau, ainsi que les dépendances entre les différentes attaques possibles et les pare-feux. A la différence des méthodes précédentes, cette approche est capable de mélanger intelligemment scans et exploits. Si cette solution exacte ne passe pas à l'échelle, de grands réseaux peuvent être traités par un algorithme de décomposition. Nos résultats expérimentaux suggèrent que c'est accompli pour une faible perte en qualité par rapport à une solution POMDP globale.

Une importante question ouverte est dans quelle mesure notre approche POMDP+decomposition est plus efficace en termes de coûts que la solution par planification classique actuellement employée par Core Security. Notre prochaine étape sera de répondre à cette question expérimentalement, en comparant la qualité des attaques de 4AL avec celle de la politique qui exécute des scans extensifs et exécute ensuite les plans de FF associés à la configuration la plus probable.

4AL est un algorithme spécifique à un domaine et, en tant que tel, ne contribue pas à la résolution de POMDP en général. A un haut niveau d'abstraction, son idée peut être comprise comme imposant un schéma sur la politique construite, restreignant ainsi l'espace des politiques explorées (et employant des algorithmes dédiés dans chaque partie du schéma). En cela, cette approche est assez similaire aux approches de décomposition de POMDP connues (par exemple, Pineau *et al.*, 2003; Müller & Biundo, 2011). Il reste à voir si cette connexion peut s'avérer fructueuse soit pour de travaux futurs en planification d'attaques, soit pour la résolution de POMDP de manière plus générale.

Les principales directions pour des travaux futurs sont de concevoir des modèles plus précis des mises à jour logicielles (donc obtenant des calculs plus réalistes de la croyance initiale); d'adapter les solveurs de POMDP à ce type particulier de problème, qui a certaines caractéristiques spécifiques, en particulier l'absence d'actions non-déterministes et le fait que certaines parties de l'état (par exemple les systèmes d'exploitation) sont statiques; et de faire progresser l'application industrielle de cette technologie. Nous espérons que tout cela inspirera aussi d'autres recherches.

## Références

- ARCE I. & MCGRAW G. (2004). Why attacking systems is a good idea. *IEEE Computer Society - Security & Privacy Magazine*, 2(4).
- BERTSEKAS D. & TSITSIKLIS J. (1996). *Neurodynamic Programming*. Athena Scientific.
- BODDY M. S., GOHDE J., HAIGH T. & HARP S. A. (2005). Course of action generation for cyber security using classical planning. In *Proc. of ICAPS'05*.
- HANSEN E. & FENG Z. (2000). Dynamic programming for POMDPs using a factored state representation. In *Proceedings of the International Conference on AI Planning and Scheduling (AIPS'00)*.
- HOFFMANN J. (2003). The Metric-FF planning system : Translating "ignoring delete lists" to numeric state variables. *Journal of Artificial Intelligence Research*, 20, 291–341.
- HOPCROFT J. & TARJAN R. (1973). Algorithm 447 : efficient algorithms for graph manipulation. *Communications of the ACM*, 16, 372–378.
- KAELBLING L., LITTMAN M. & CASSANDRA A. (1998). Planning and acting in partially observable stochastic domains. *Artificial Intelligence*, 101(1–2), 99–134.
- KURNIAWATI H., HSU D. & LEE W. (2008). SARSOP : Efficient point-based POMDP planning by approximating optimally reachable belief spaces. In *Robotics : Science and Systems IV*.
- LUCANGELI J., SARRAUTE C. & RICHARTE G. (2010). Attack planning in the real world. In *Workshop on Intelligent Security (SecArt 2010)*.
- MONAHAN G. (1982). A survey of partially observable Markov decision processes. *Management Science*, 28, 1–16.
- MÜLLER F. & BIUNDO S. (2011). HTN-style planning in relational POMDPs using first-order FSCs. In *Proceedings of the 34th German Conference on AI (KI'11)*, p. 216–227.
- PINEAU J., GORDON G. & THRUN S. (2003). Policy-contingent abstraction for robust robot control. In *Proceedings of the 19th Conference on Uncertainty in Artificial Intelligence (UAI'03)*, p. 477–484.
- SARRAUTE C., BUFFET O. & HOFFMANN J. (2011a). Penetration testing == POMDP solving ? In *Proceedings of the 3rd Workshop on Intelligent Security (SecArt'11)*.
- SARRAUTE C., RICHARTE G. & LUCANGELI J. (2011b). An algorithm to find optimal attack paths in nondeterministic scenarios. In *ACM Workshop on Artificial Intelligence and Security (AISec'11)*.