

Vérification distribuée à la volée de grands espaces d'états

Christophe Joubert

INRIA Rhône-Alpes / VASY

<http://www.inrialpes.fr/vasy>

12 décembre 2005

Thèse réalisée sous la direction de
Radu Mateescu et Hubert Garavel



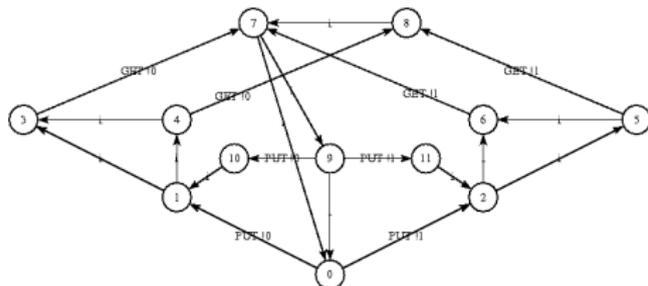
Vérification formelle



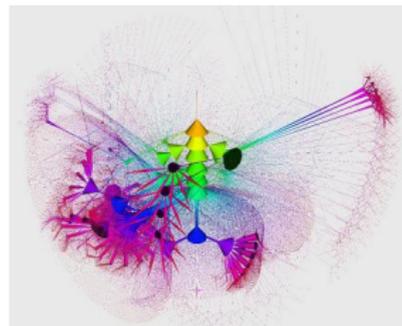
- ▶ **Objectif** : produire des **logiciels fiables**
- ▶ **Mise en œuvre** : utiliser des modèles formels et les capacités de calcul des ordinateurs pour **analyser leur comportement**
- ▶ **Cibles** : systèmes informatiques **critiques**, impliquant coût humain ou financier élevé
- ▶ **Exemple** : perte du satellite Cryosat - 08/10/05 - **erreur logicielle** sur le lanceur Rockot - 136 M €

Modèle formel : système de transitions étiquetées (STE)

- ▶ Comportement simplifié d'un **protocole** d'échange de données entre deux ordinateurs :

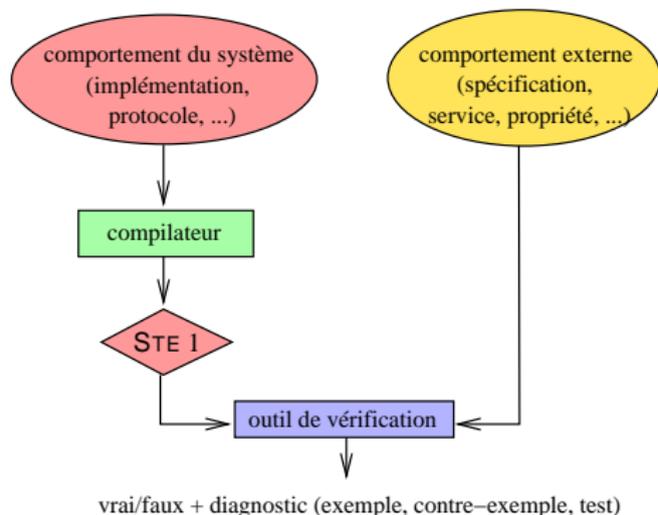


- ▶ STE de **taille réaliste** (10^5 états, 10^5 transitions) issue de la base de tests **VLTS** :



- ▶ Support logiciel (CADP) pour la représentation de STE :
 - *explicite* (fonction prédécesseur/successeur) – BCG (Binary Coded Graph)
 - *implicite* (fonction successeur) – **OPEN/CÆSAR** [Garavel-98]

Vérification énumérative



► **Vérification globale**

- STE construit **avant** la vérification

► **Vérification à la volée**

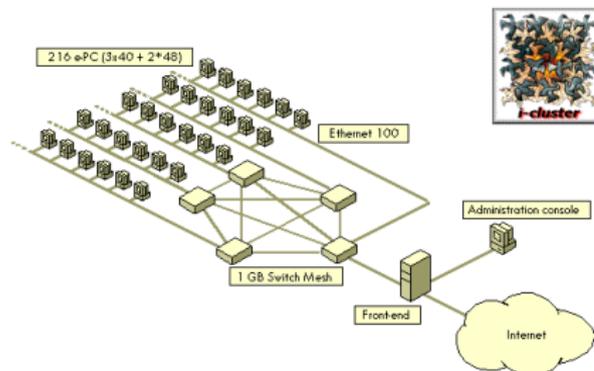
- STE construit **pendant** la vérification
- Possibilité d'exploration **partielle** du STE pour obtenir le résultat

► **Problème d'explosion d'états**

Vérification distribuée

- ▶ Utiliser la **puissance de calcul** et l'**espace mémoire** de machines interconnectées pour résoudre des problèmes complexes

- ICLUSTER (INRIA/ID)
216 PIII 733 MHz 256 Mb



- IDPOT
48 Bi-Xeon 2.5 GHz 1.5 Gb



<http://www.grid5000.org/>



Quatre grands problèmes abordés dans la thèse

Vérification énumérative

- ▶ **Comparaison** à la volée par équivalence
- ▶ **Minimisation** à la volée (τ -confluence)
- ▶ **Evaluation** à la volée de formules de logique temporelle

Génération de test

- ▶ **Génération** à la volée de cas de tests de conformité

Approche générique aux quatre grands problèmes

⇒ Résolution de **systemes d'équations booléennes** (SEBS)
avec **diagnostic**

Vérification énumérative

- ▶ **Relations d'équivalences**

[Andersen-Vergauwen-95], [Mateescu-03]

- ▶ **τ -confluence** [Pace-Lang-Mateescu-03]

- ▶ **Formules de μ -calcul modal**

[Andersen-94], [Mateescu-Sighireanu-02]

Génération de test

- ▶ **Cas de tests conformes**



Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
3. Trois applications en vérification énumérative
4. Application à la génération de tests
5. Conclusion et perspectives

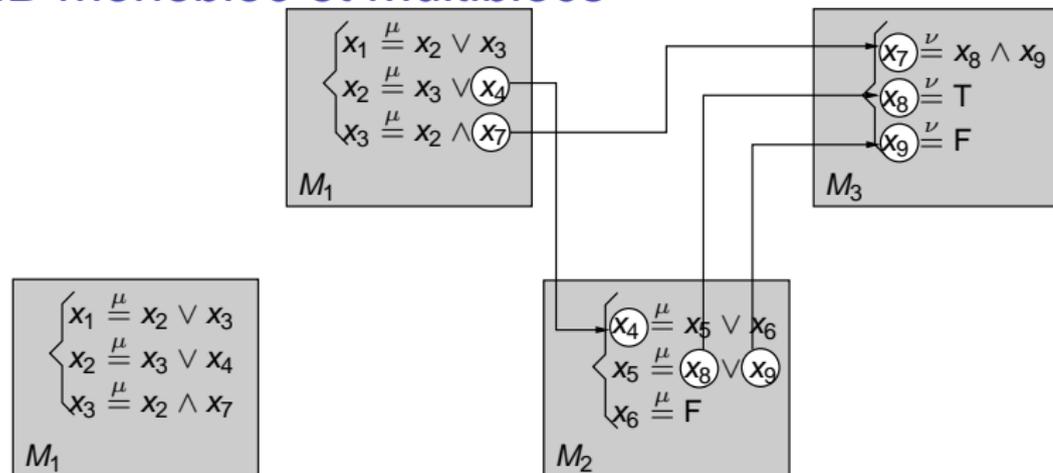


Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
3. Trois applications en vérification énumérative
4. Application à la génération de tests
5. Conclusion et perspectives



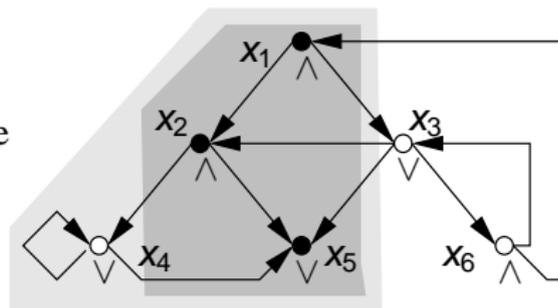
SEB monobloc et multiblocs



- ▶ Ensemble d'équations booléennes de point fixe
 $(M_i = \{x_j \stackrel{\sigma_i}{=} op_j x_j\}_{1 \leq j \leq m_i, 1 \leq i \leq n})$
- ▶ Formules purement disjonctives ou conjonctives (SEB **simple**)
- ▶ n blocs M_i ($i \in [1..n]$) avec dépendances inter-blocs acycliques

Graphe booléen et résolution de SEB

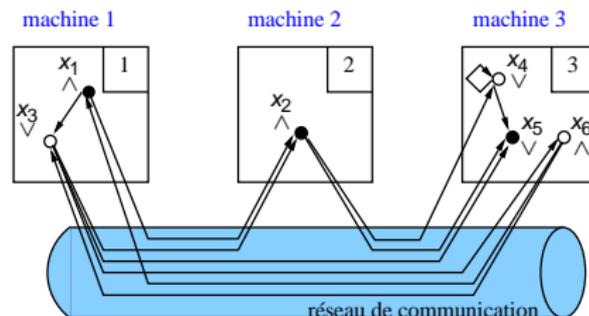
- : *vrai*
- : *faux*
- : portion explorée durant une résolution DFS à la volée
- : diagnostic



- ▶ **Graphe booléen $G = (V, E, L)$ associé à un SEB (de signe ν)**
 - V = ensemble des variables
 - E = ensemble des arêtes
 - L = signe des variables (\vee, \wedge)
- ▶ **Résolution locale séquentielle [Mateescu-03]**
 - Valeur de vérité de la **variable principale**
 - Génération de **diagnostic** (sous-graphe booléen)

Distribution de la résolution de SEB

- ▶ **Objectif** : répartir le coût en mémoire sur plusieurs machines (limite actuelle 10^7 variables) et diminuer le temps de résolution (proportionnel à la taille du SEB)
- ▶ **Méthode** : distribution naturelle et équilibrée du problème de résolution de SEB par répartition des variables sur les différents processus



Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
 - Résolution de SEB monobloc
 - Résolution de SEB multiblocs
 - Bibliothèque générique CAESAR_SOLVE_2
3. Trois applications en vérification énumérative
4. Application à la génération de tests
5. Conclusion et perspectives

Résolution de SEB monobloc

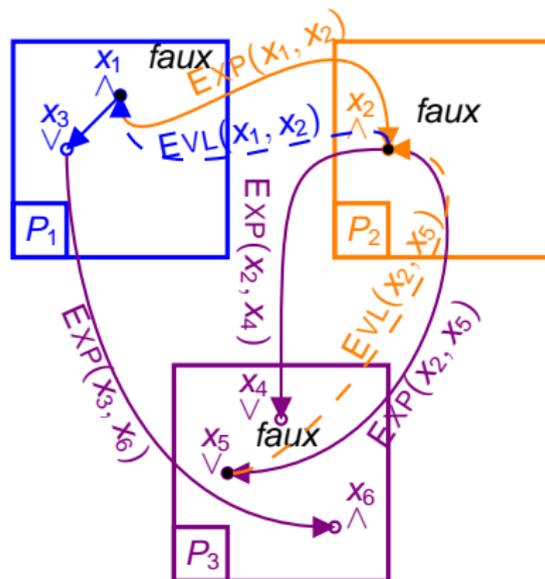
Modèle de calcul

- ▶ Architecture à mémoire distribuée (**passage de messages**) : grappe de PCs
- ▶ P processus **SPMD** et 1 processus **superviseur**
- ▶ Chaque processus résout un sous-ensemble des variables booléennes (**fonction de hachage statique**)

Algorithme distribué : DSOLVE

- ▶ **Exploration en avant** du graphe booléen (V, E, L) à partir de la variable principale $x \in V$
- ▶ **Propagation arrière** de variables stables
- ▶ **Distribution** des variables à travers les dépendences distantes
- ▶ **Détection de terminaison** : x stable **ou** graphe booléen entièrement résolu

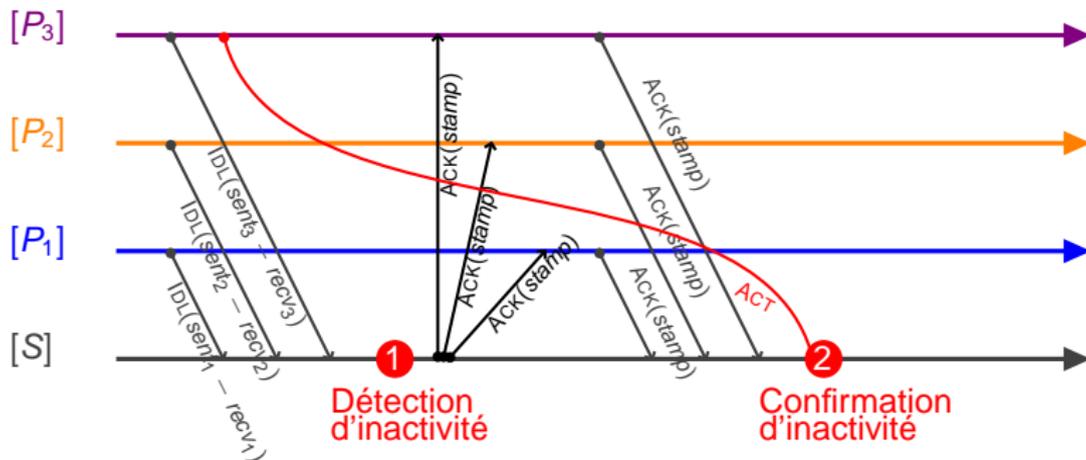
Exécution de DSOLVE



- 1 Initialisation (variable principale x_1)
- 2 **Expansion locale** et **expansion distante** (message **EXP**)
- 3 Variable conjonctive sans successeur (i.e., constante **fausse**)
- 4 Propagation arrière locale et distante (message **EVL**) de variables stabilisées (i.e., calculées)
- 5 Si la variable principale se stabilise, alors la résolution se termine

Algorithme de détection distribuée de terminaison (DDT)

- ▶ Deux vagues de détection d'inactivité globale entre le processus superviseur et les processus de résolution



Résultats de complexité

Pour un graphe booléen (V, E, L) et P processus de résolution :

- ▶ Complexité en **temps** dans le pire des cas = $O(|V| + |E|)$
 - deux parcours de graphe (avant et arrière) entrelacés
- ▶ Complexité en **mémoire** dans le pire des cas = $O(|V| + |E|)$
 - Dépendances stockées durant l'exploration du graphe
- ▶ Complexité en nombre de **messages** = $O(|E|)$
 - deux messages (expansion et stabilisation) sont au plus échangés par transition
- ▶ Détection distribuée de **terminaison** = $O(|E|)$
 - deux vagues avec $3P$ messages au plus échangés par transition

Résolution de SEB multiblocs

- ▶ **Approche séquentielle** [Mateescu-03] :
 - appels récursifs de résolution par bloc
 - pile d'appels bornée par le nombre de blocs du SEB
- ▶ **Approche distribuée naïve** (DSOLVE) :
 - une seule résolution pour le SEB entier
 - détection de terminaison du SEB entièrement résolu

→ **incompatible** ou **inefficace** avec résolution distribuée de SEB multiblocs

- ▶ **Solution adoptée** :
 - distinction des **variables** de blocs différents
 - détection distribuée de **terminaison** par bloc
 - gestion de deux **parcours** (avant et arrière) par bloc

Résolution distribuée de SEB multiblocs

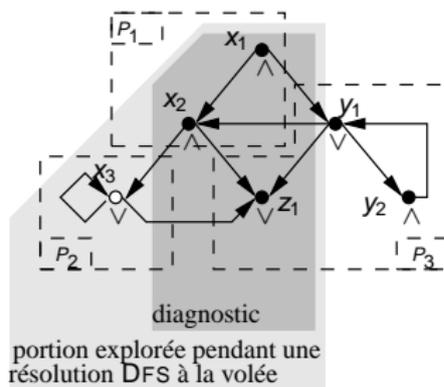
- ▶ Extension **conservative** de l'algorithme DSOLVE \implies modèle de calcul identique

Algorithme distribué MB-DSOLVE

- ▶ Choix du **numéro de bloc** parmi ceux en attente d'**exploration** ou de **stabilisation**
- ▶ Priorité à la stabilisation de **bloc de plus haut niveau** dans l'arbre des dépendances entre blocs
- ▶ Limitation des **requêtes d'exploration** : une seule portion de bloc explorée à la fois, et priorité au **bloc de plus bas niveau**
- ▶ Gestion des transitions interblocs **non stabilisées** : propagations **résiduelles**
- ▶ Détection distribuée de **portion de bloc résolu**

Exemple de résolution distribuée à la volée de SEB multiblocs

$$\begin{array}{l}
 \text{bloc 1} \quad \left\{ \begin{array}{l} x_1 \stackrel{\nu}{=} x_2 \wedge y_1 \\ x_2 \stackrel{\nu}{=} x_3 \wedge z_1 \\ x_3 \stackrel{\nu}{=} x_3 \vee z_1 \end{array} \right. \\
 \text{bloc 2} \quad \left\{ \begin{array}{l} y_1 \stackrel{\mu}{=} x_2 \vee x_{1,3} \vee y_2 \\ y_2 \stackrel{\mu}{=} y_1 \end{array} \right. \\
 \text{bloc 3} \quad \left\{ \begin{array}{l} z_1 \stackrel{\nu}{=} F \end{array} \right.
 \end{array}$$



- ▶ Points fixes pouvant être différents entre les blocs
- ▶ Transitions interblocs à stabiliser

Bibliothèque générique CAESAR_SOLVE_2

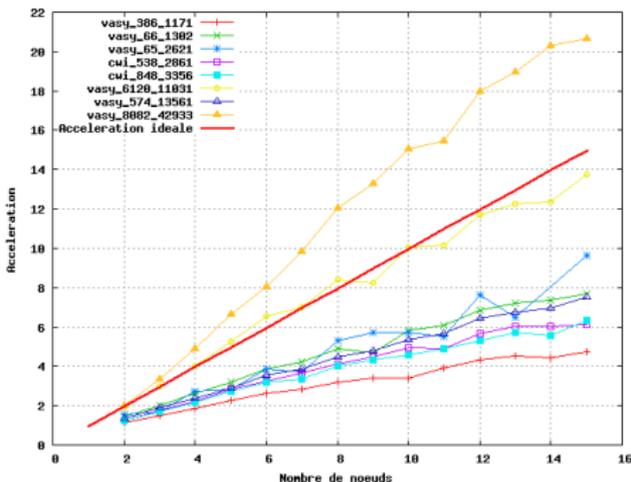
- ▶ **Résolution** distribuée à la volée de SEBs sans alternance et génération distribuée à la volée de **diagnostics** (sous-graphes booléens)
 - SEB monobloc - **DSOLVE** (10 000 lignes de code C)
 - SEB multiblocs - **MB-DSOLVE** (7 000 lignes de code C supplémentaires)
- ▶ Testée avec un **générateur** (1000 lignes de code C) paramétré de SEBs aléatoires
- ▶ Connectée à une **bibliothèque** prototype et générique de **communication** à travers des sockets TCP/IP
- ▶ **API** de résolution booléenne **générique et indépendante** de l'application, donnée par la bibliothèque **CAESAR_SOLVE_1** [Mateescu-03]

Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
3. Trois applications en vérification énumérative
 - BISIMULATOR : comparateur à la volée par équivalences
 - TAU_CONFLUENCE : réducteur à la volée par tau-confluence
 - EVALUATOR 3.5 : évaluateur à la volée de formules logiques
4. Application à la génération de tests
5. Conclusion et perspectives



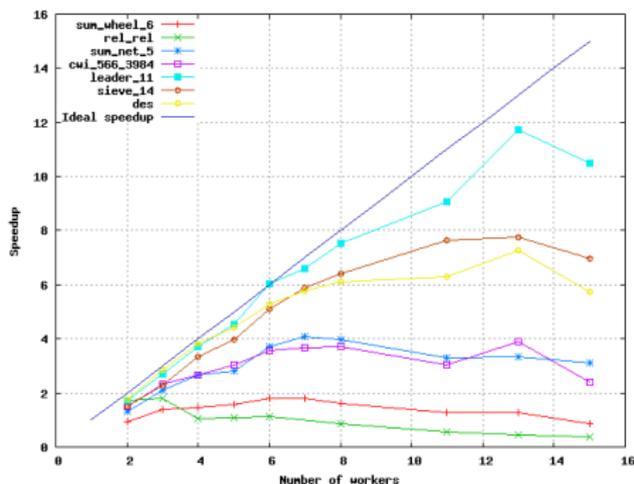
BISIMULATOR distribué vs. séquentiel



- ▶ **Equivalence forte** : meilleur comportement parmi toutes les équivalences (très peu de temps dans le calcul des successeurs)
- ▶ Accélérations **linéaires**
- ▶ **vasy_6120_11031** (VLTS) :
 - 169.47 s. en séquentiel
 - 11.69 s. avec **15 processus**, accélération de **14.5**

- ▶ Surcoût mémoire **constant** (4 fois celui séquentiel)
 - quel que soit le nombre de nœuds de calcul
 - pour une **taille de problèmes** à résoudre

TAU_CONFLUENCE distribué vs. séquentiel

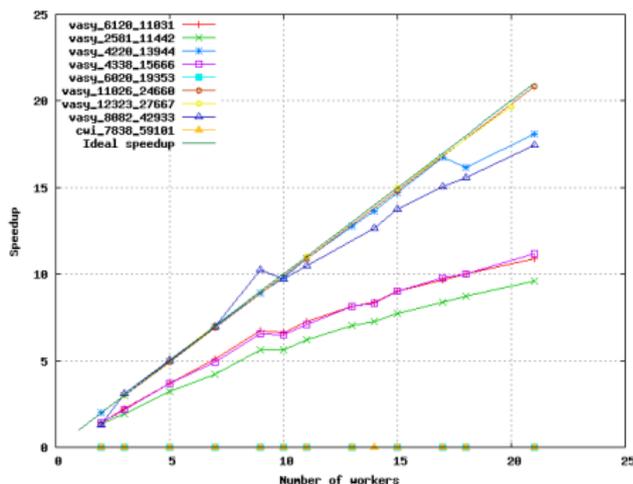


- ▶ **Accélération** proche du linéaire en nombre de noeuds utilisés
- ▶ **Réduction** entre un et quatre ordres de grandeur (comme en séquentiel)
- ▶ Limitations dans certains cas :
 - Parcours BFS avec **appel de résolution** pour chaque τ -transition
 - DDT forçant les noeuds à souvent se **synchroniser**
 - **Solution alternative** : appel sur un ensemble de τ -transitions

▶ Surcoût mémoire **constant** (3 fois celui séquentiel)

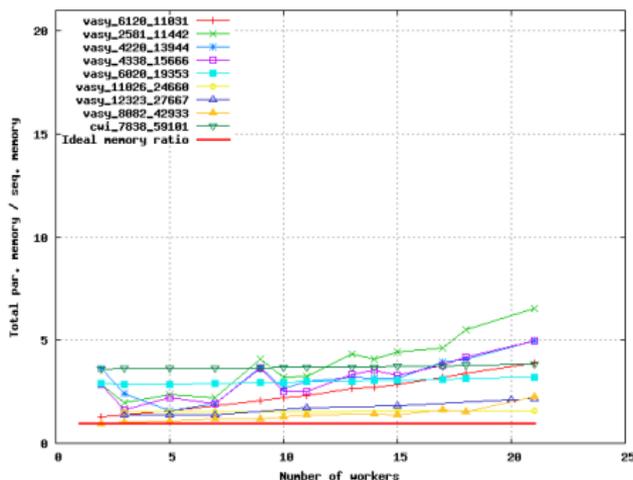
- quel que soit le nombre de noeuds de calcul
- très **peu dépendant** de la taille du problème

EVALUATOR 3.5 distribué vs. séquentiel (temps)



- ▶ **Accélération** proche du linéaire
- ▶ **Comparable** en temps et mémoire à UppDMC (model-checker distribué)
- ▶ Gain en temps significatif pour l'exemple *vasy_12323_27667* (VLTS) et la présence de **famine** :
 - **> 2 jours** en séquentiel DFS optimisé
 - **< 3h** en distribué sur **20 noeuds**, accélération de **19.7**
- ▶ Détection immédiate de **diagnostics**

EVALUATOR 3.5 distribué vs. séquentiel (mémoire)



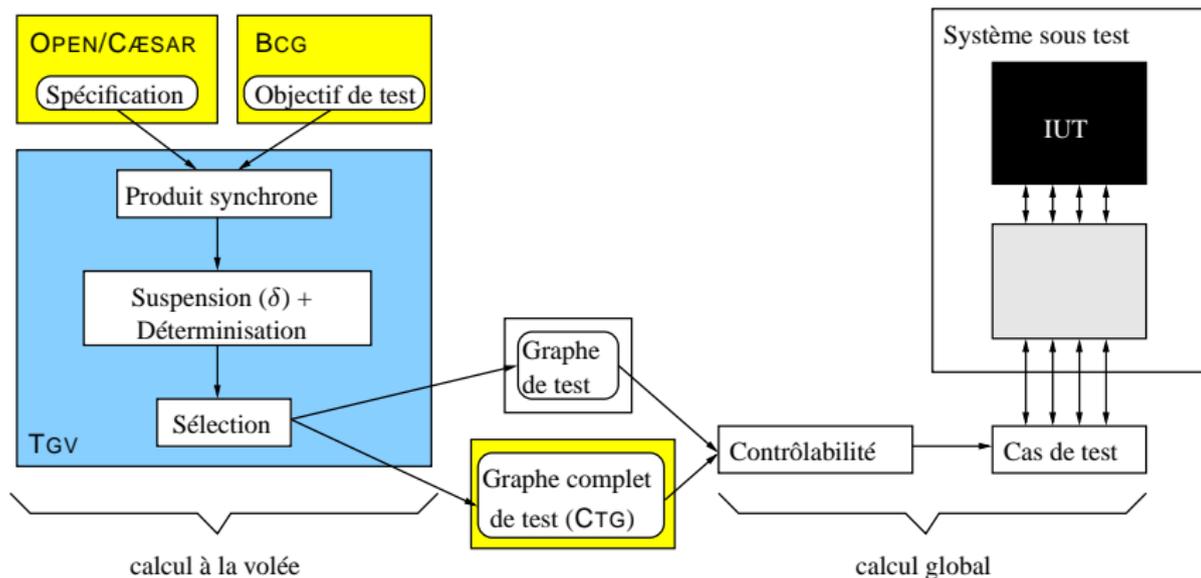
- ▶ Surcoût mémoire **constant** (4 fois celui séquentiel) :
 - quel que soit le nombre de nœuds de calcul
 - pour une **formule** et sa **valeur de vérité** (détection de contre-exemples ou non)
 - ▶ Evaluator distribué pour d'autres logiques temporelles :
 - **ACTL**, par traduction en μ -calcul modal sans alternance
- [Fantechi-Gnesi-Ristori-92]

Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
3. Trois applications en vérification énumérative
4. Application à la génération de tests
 - TGV : générateur à la volée de cas de tests
 - EXTRACTOR : générateur à la volée de cas de test
5. Conclusion et perspectives

TGV : générateur à la volée de cas de tests

- [Fernandez-Jard-Jeron-Viho-96], [Jard-Jeron-05]



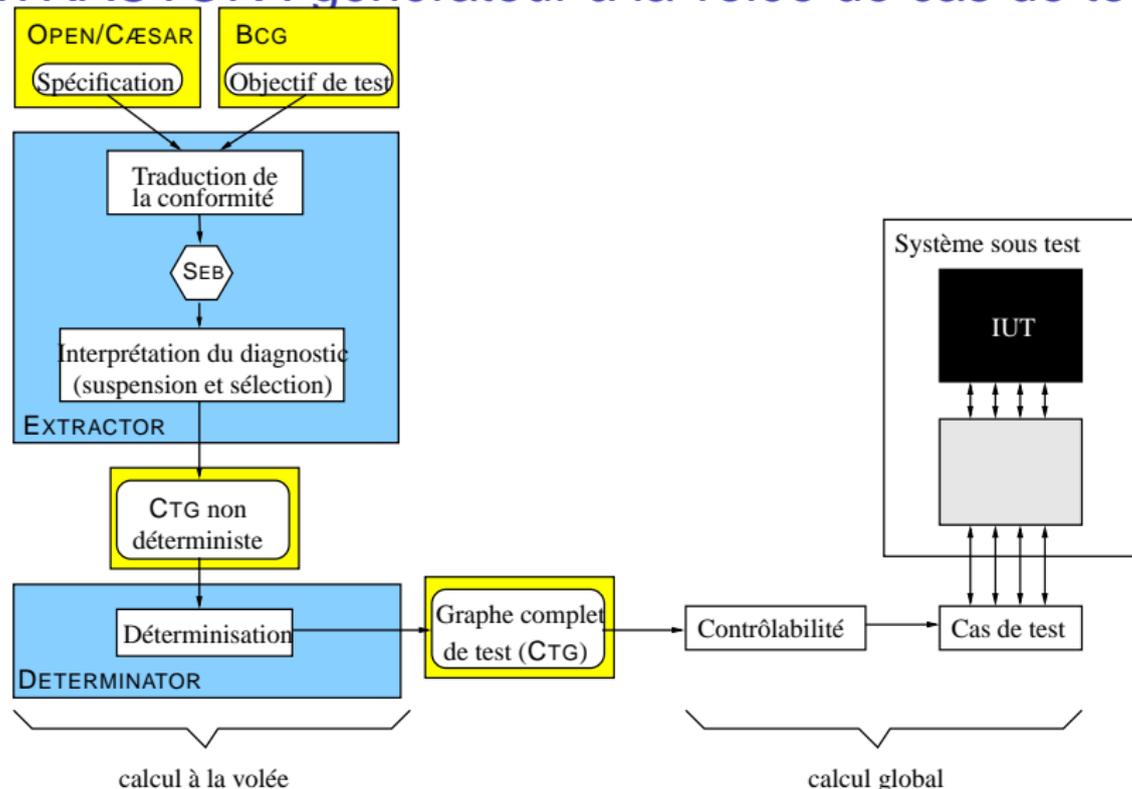
Traduction des cas de tests en termes de SEBs

- ▶ Génération de tests =
 - cas particulier de génération de **diagnostic** pour une **formule de μ -calcul** modal sans alternance
 - cas particulier de génération de **diagnostic** pour un **SEB multiblocs**
- ▶ Définition du SEB multiblocs correspondant :

$$\begin{cases} X_s & =_{\nu} & Y_s \wedge \bigwedge_{s \rightarrow s'} (Z_{s'} \vee X_{s'}) \\ Y_s & =_{\mu} & \bigvee_{s \xrightarrow{acc} s'} T \vee \bigvee_{s \rightarrow s'} Y_{s'} \\ Z_s & =_{\nu} & \bigwedge_{s \xrightarrow{acc} s'} F \wedge \bigwedge_{s \rightarrow s'} Z_{s'} \end{cases}$$

- ▶ Avantages :
 - solution **générique**
 - obtention directe d'un **générateur distribué** à la volée de cas de tests

EXTRACTOR : générateur à la volée de cas de tests



EXTRACTOR vs. TGV

- ▶ Accélération :

$$\frac{\sum_{\text{STEs}} \text{temps}(\text{TGV})}{(\sum_{\text{STEs}} \text{temps}(\text{EXTRACTOR}) + \sum_{\text{CTGs intern.}} \text{temps}(\text{DETERMINATOR}))} = 1.82$$

- ▶ Consommation mémoire :

$$\frac{\sum_{\text{STEs}} \text{memoire}(\text{TGV})}{(\sum_{\text{STEs}} \text{memoire}(\text{EXTRACTOR}) + \sum_{\text{CTGs intern.}} \text{memoire}(\text{DETERMINATOR}))} = 1.05$$

- ▶ Taille des CTGs :

$$\frac{\sum_{\text{STEs}} \text{nombreEtats}(\text{TGV})}{\sum_{\text{CTGs intern.}} \text{nombreEtats}(\text{DETERMINATOR})} = 0.71$$

$$\frac{\sum_{\text{STEs}} \text{nombreTrans}(\text{TGV})}{\sum_{\text{CTGs intern.}} \text{nombreTrans}(\text{DETERMINATOR})} = 0.53$$

- ▶ Exemples traités sur lesquels TGV échoue :

EXEMPLE	M états	M trans.	EXTRACTOR + DETERMINATOR
<i>cwi_214_684</i>	214	684	8 s., 19 Mo, aucun cas de test
<i>cwi_566_3984</i>	566	3 984	1195 s., 145 Mo, (32 états, 49 trans.)

Plan de l'exposé

1. Systèmes d'Equations Booléennes
2. Résolution distribuée à la volée de SEBs
3. Trois applications en vérification énumérative
4. Application à la génération de tests
5. Conclusion et perspectives
 - Bilan
 - Perspectives

Bilan

- 1 Moteur **générique** de vérification distribuée à la volée :
 - Résolution de SEB monobloc (**DSOLVE**)
 - Résolution de SEB multiblocs (**MB-DSOLVE**)
- 2 **Connexion** à des outils réels de vérification formelle :
 - **Comparaison** à la volée par équivalences (**BISIMULATOR**)
 - **Réduction** à la volée par ordre partiel (**TAU_CONFLUENCE**)
 - **Evaluation** à la volée de formules de logiques temporelles (**EVALUATOR**)
- 3 **Application** à la génération de tests :
 - Traduction de la génération à la volée de **cas de test de conformité** en termes de SEBS (**EXTRACTOR**)
- 4 **Expérimentation massive** des outils sur **cas d'études industrielles** et **machines parallèles réelles**

Perspectives

- ▶ Compléter les **applications existantes** :
 - Traduction d'autres équivalences : bisimulation Markovienne [Hermanns-Siegle-99]
 - Traduction d'autres réductions : tau-inertness [Groote-Sellink-90], tau-confluence faible [Groote-vandePol-00]
- ▶ Développer d'**autres applications** à partir de DSOLVE et MB-DSOLVE :
 - Résolution de clauses de Horn [Liu-Smolka-98]
 - Analyse de flot de données et interprétation abstraite [Fecht-Seidl-96]
- ▶ Etudier d'**autres stratégies** de résolution de SEBS
- ▶ Généraliser l'approche à des **architectures hétérogènes**, telles que les Nows, puis les **grilles de calcul**

Bibliographie

-  C. Joubert et R. Mateescu.
Distributed On-the-Fly Equivalence Checking and τ -Confluence Reduction.
FMSD'2006, en cours de publication.
-  D. Bergamini, N. Descoubes, C. Joubert et R. Mateescu.
BISIMULATOR : A Modular Tool for On-the-Fly Equivalence Checking.
TACAS'2005, LNCS 3440 :581–585.
-  C. Joubert et R. Mateescu.
Distributed Local Resolution of Boolean Equation Systems.
PDP'2005, IEEE 264–271.
-  C. Joubert et R. Mateescu.
Distributed On-the-Fly Equivalence Checking.
PDMC'2004, ENTCS 128(3).
-  Christophe Joubert.
Distributed Model-Checking : From Abstract Algorithms to Concrete Implementations.
PDMC'2003, ENTCS 89(1).
-  H. Hermanns et C. Joubert.
A Set of Performance and Dependability Analysis Components for CADP.
TACAS'2003, LNCS 2619 :425–430.