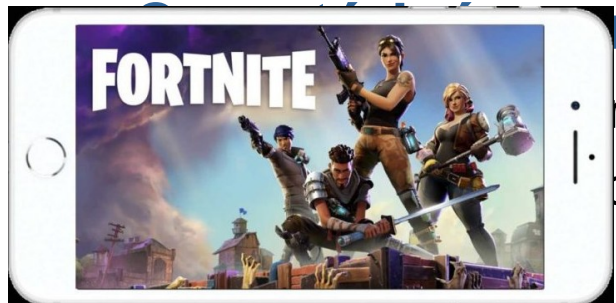


# Accélération Matérielle pour la Traduction Dynamique de Programmes Binaires

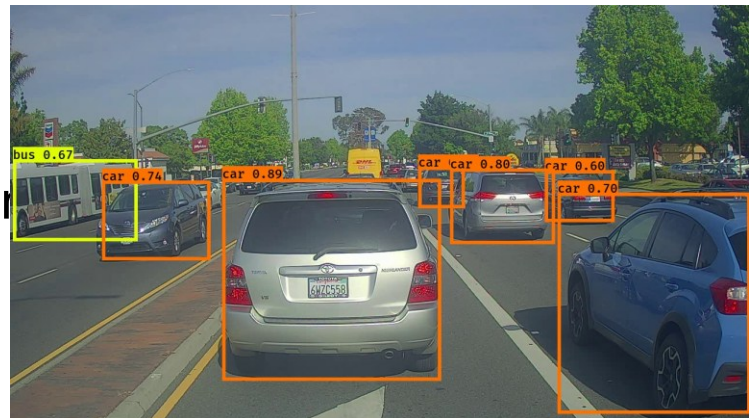
Simon Rokicki, Steven Derrien, Erven Rohou

# Qu'est-ce qu'un système embarqué ?

- Système autonome, parfois spécialisé pour une tâche




Performance  
Consommation



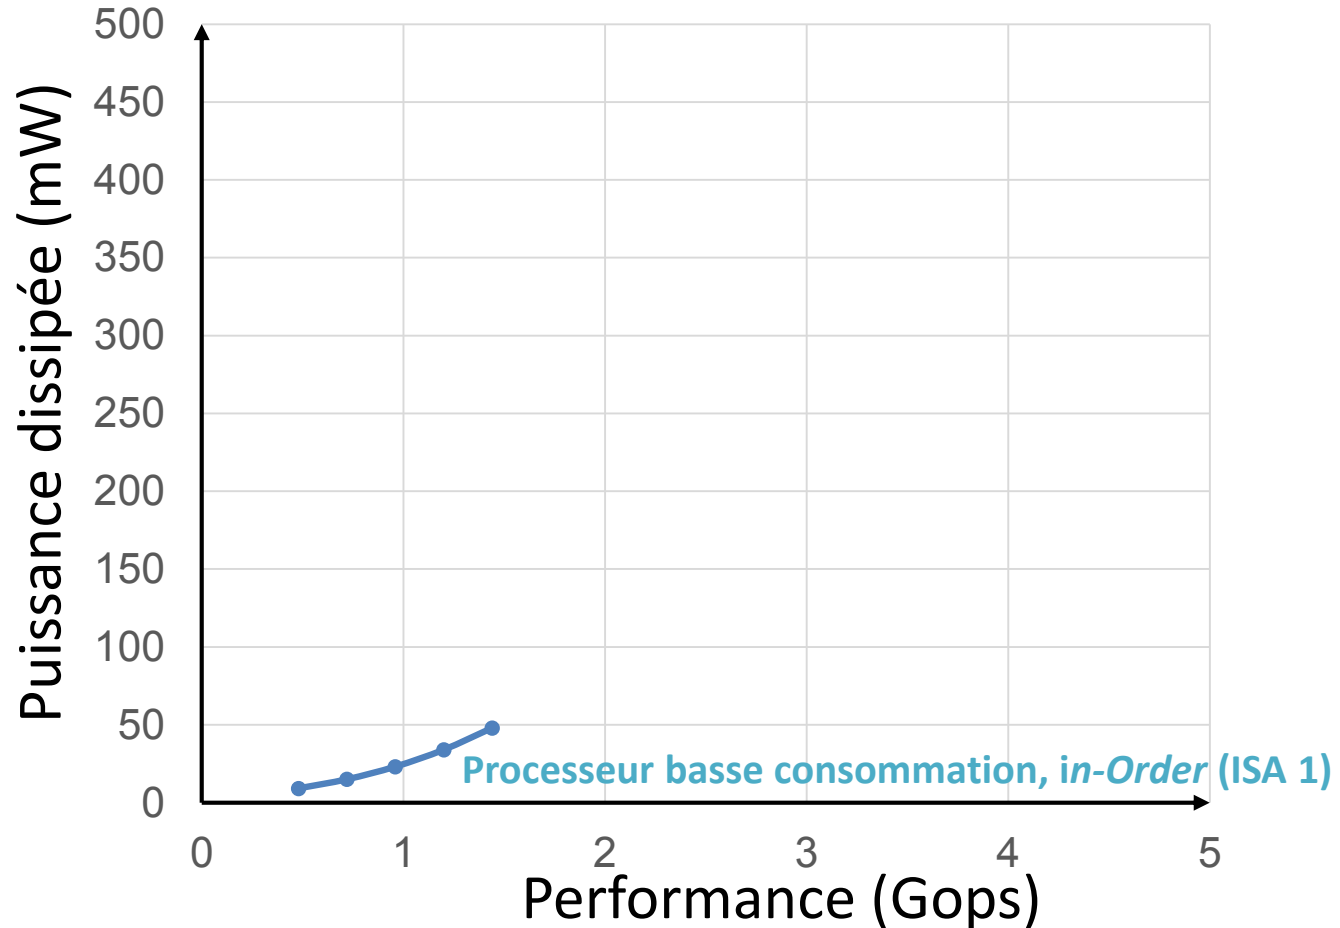

# Compromis performance/énergie

- Différents profils de fonctionnement
  - Besoin de minimiser la consommation énergétique
  - Besoin de maximiser les performances
- **Contrôle dynamique du compromis performance/énergie**



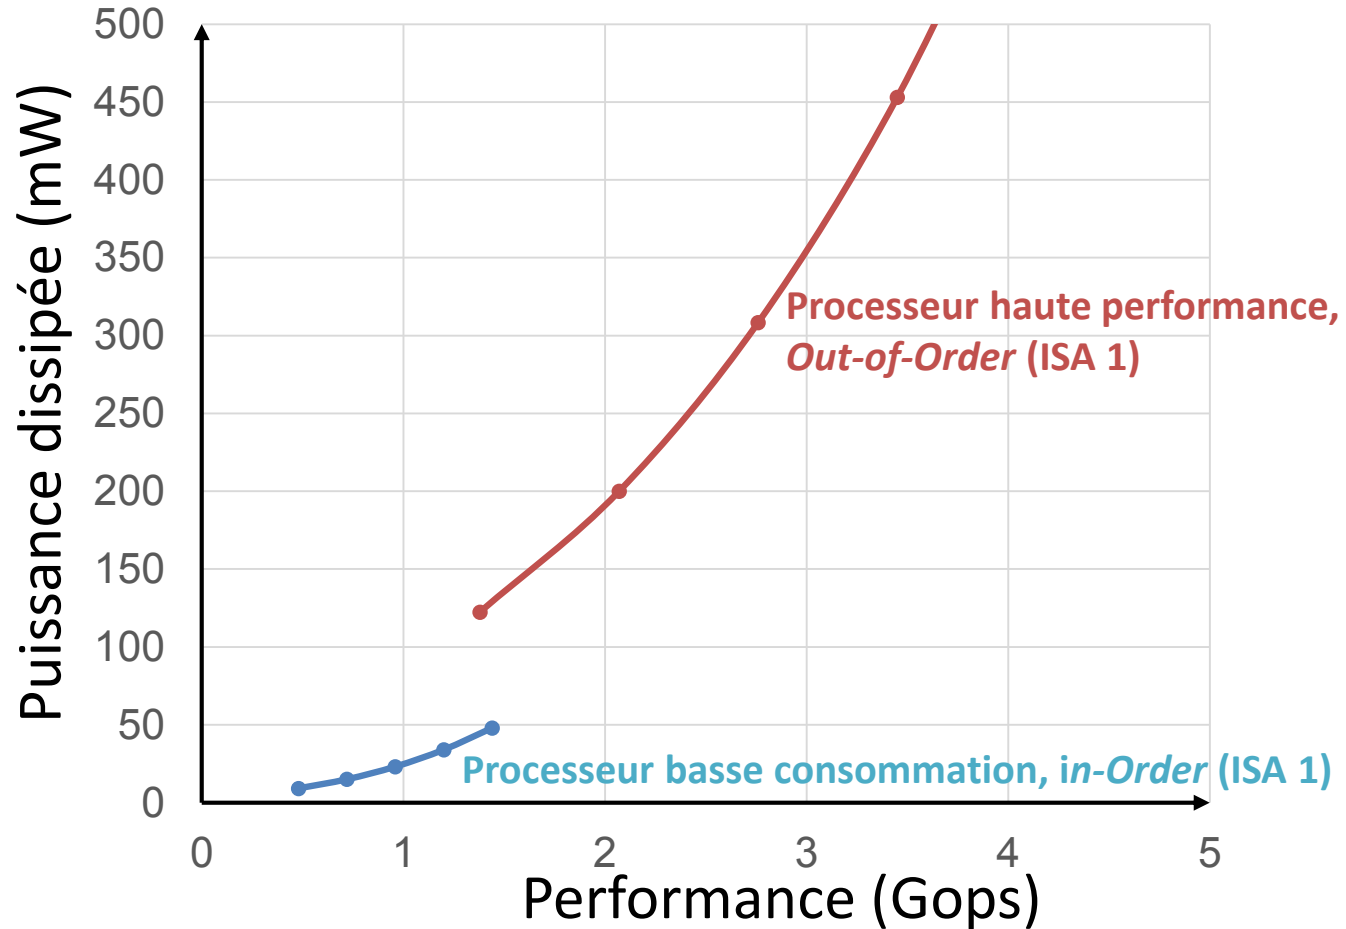
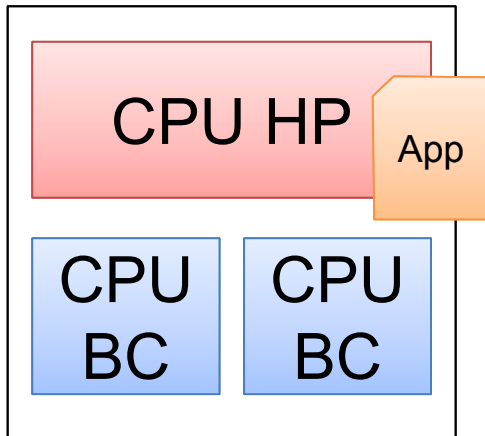
# Compromis performance/énergie

Système



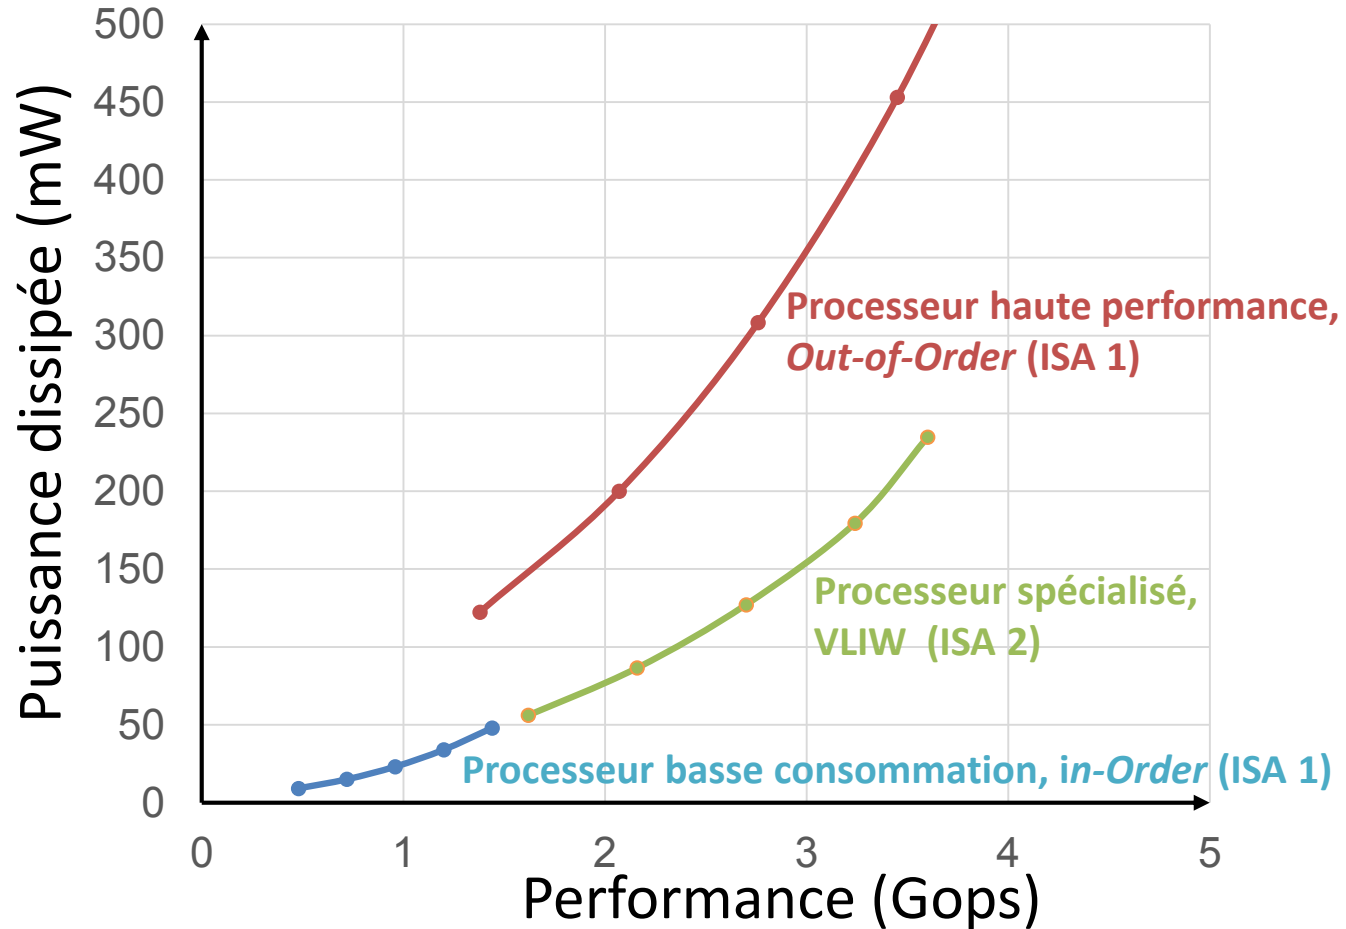

# Compromis performance/énergie

Systeme




# Compromis performance/énergie

Systeme



# Traduction dynamique de binaires

Système

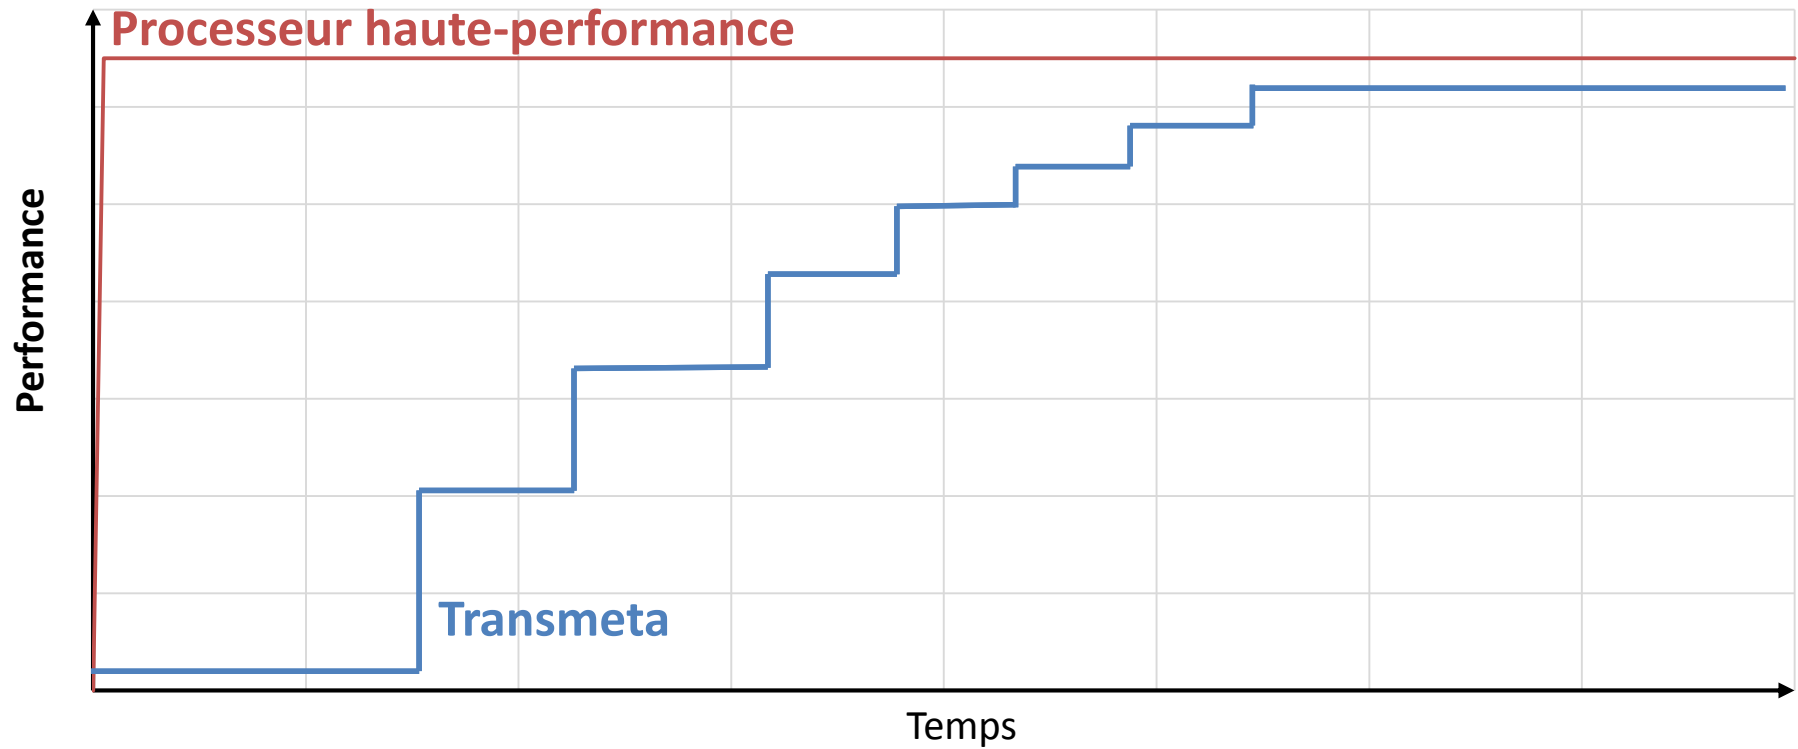


- **Principe :**  
**Traduire et optimiser (pendant l'exécution) une application d'un ISA 1 vers un ISA 2**
- **Exemples de processeurs basés sur la DBT :**

TRANSMETA™



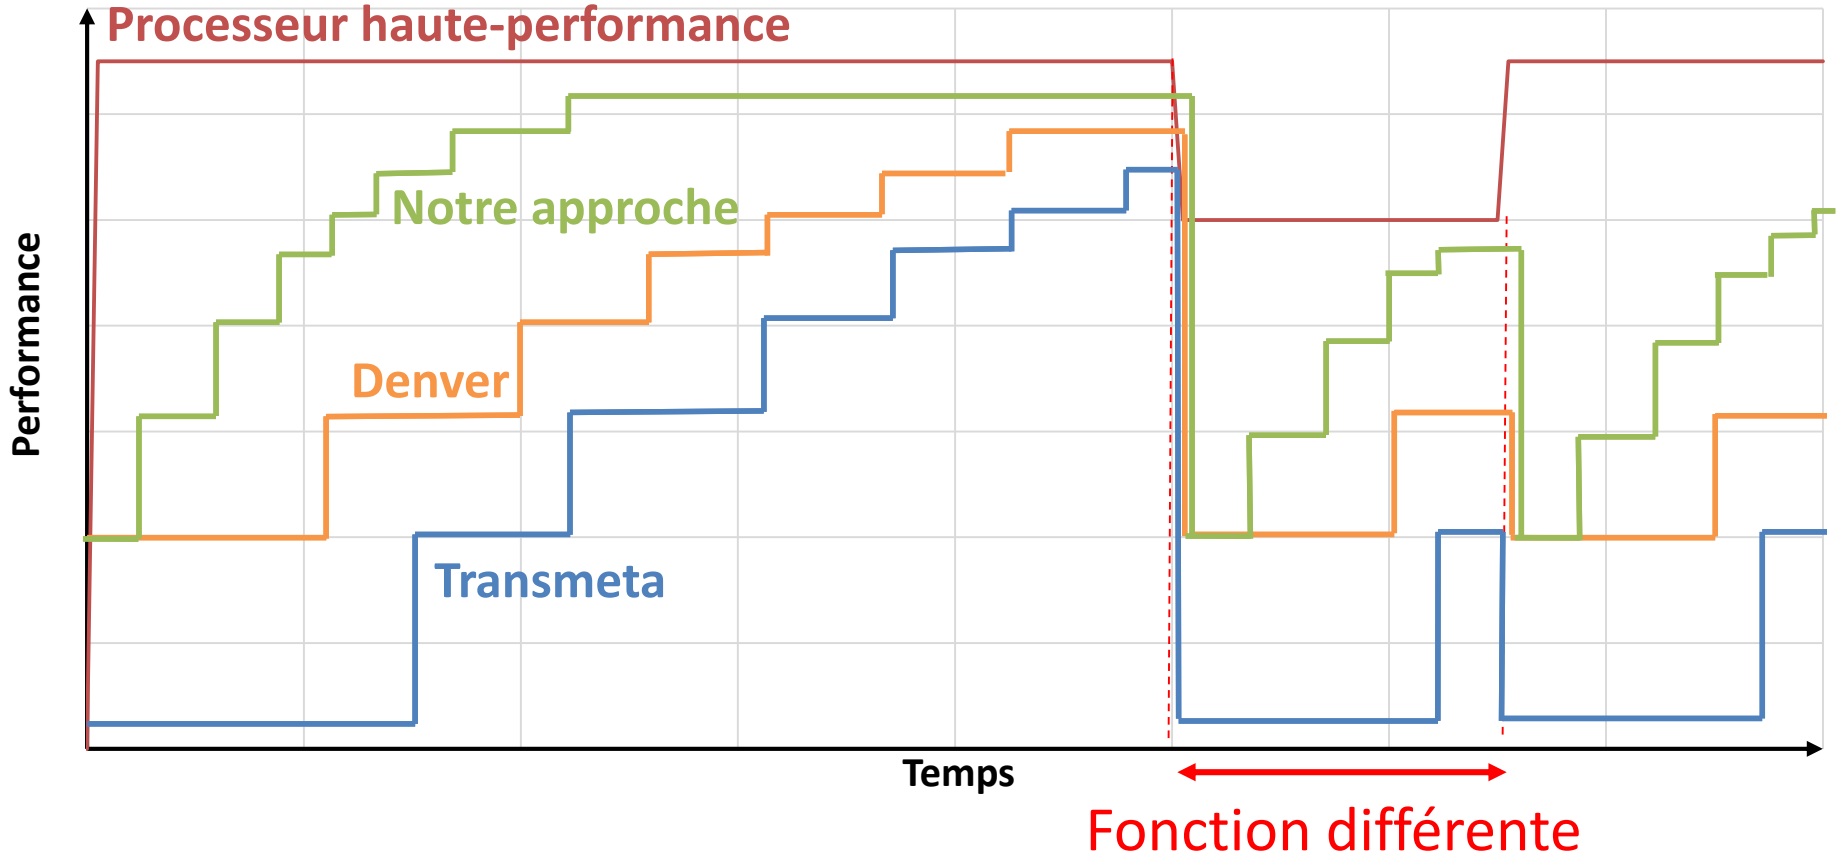
# Performance de la DBT



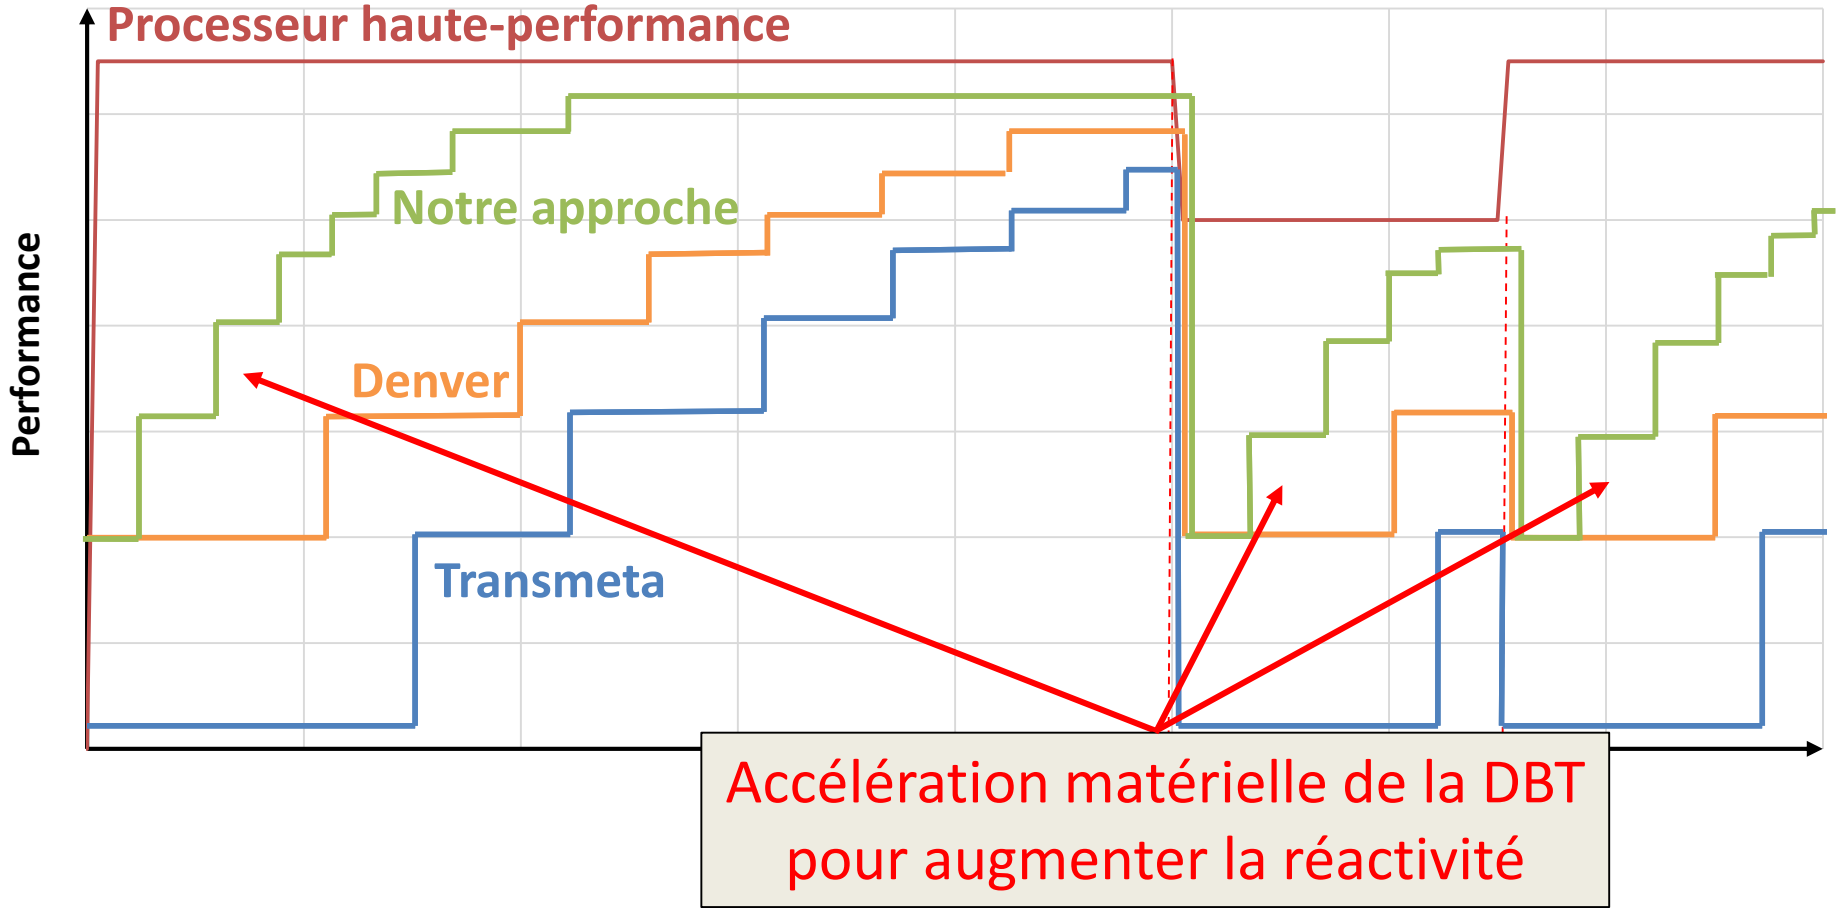
Références : *McFarlin2013*



# Performance de la DBT



# Performance de la DBT



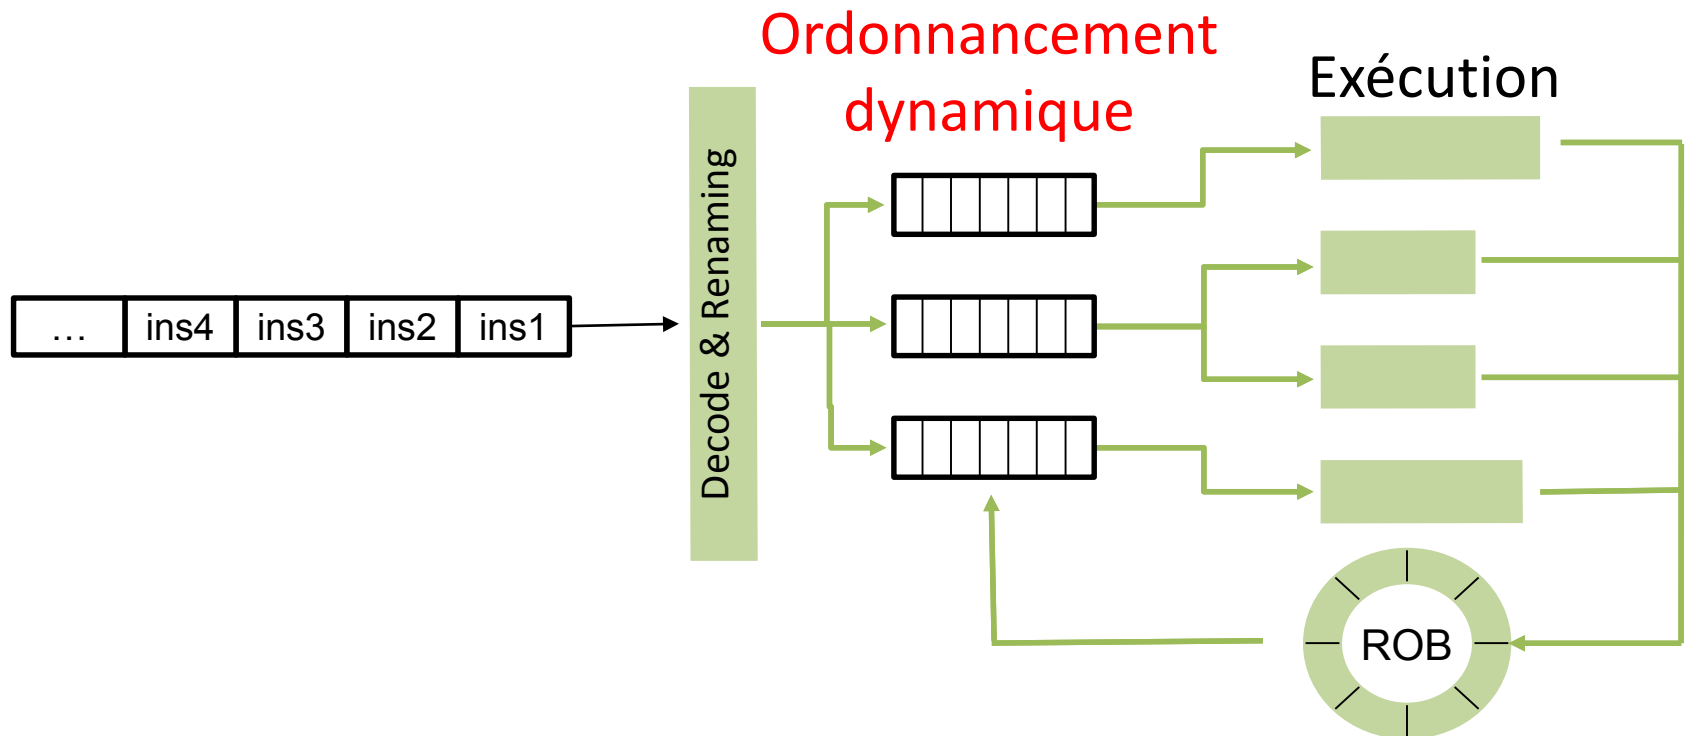
Accélération matérielle de la DBT pour augmenter la réactivité

# Plan de la présentation

- **Etat de l'art**
  - Architecture des processeurs
  - Traduction Dynamique de Binaires
- **Accélération matérielle de la DBT**
- **Conclusion**

# Processeurs Out-of-Order (OoO)

- Extraction dynamique de l'ILP
- Exécution spéculative




**ROB:** *Re-Order Buffer*

**ILP:** *Instruction Level Parallelism* – Parallélisme d'instruction

# Les OoO dans l'embarqué

- **Mécanismes très coûteux**
  - Les ordonnancements sont recalculés à chaque exécution
- **Comment réduire ces coûts ?**
  - Dans l'embarqué : processeurs OoO moins agressifs
  - Essayer de ne pas recalculer les ordonnancements
- **Approches proposées :**
  - réutilisation sur des architectures plus spécialisées  
(*Padmanabha2017, Brandalero2017, Villavieja2014*)
  - Preuves de concept académiques

# Processeurs VLIW


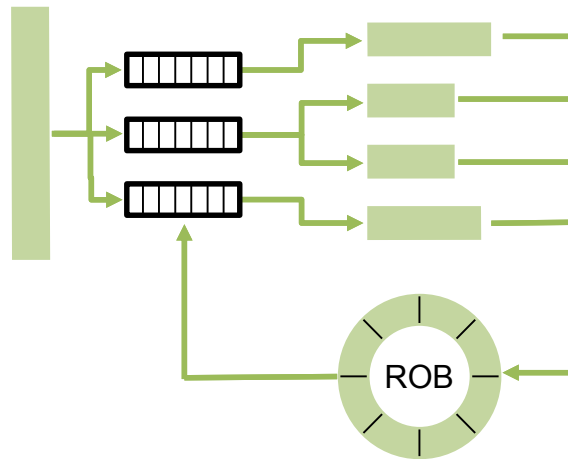


**Bundles : Groupements d'instructions indépendantes**

- **ISA explicitement parallèles**
  - Efficacité énergétique
- **ILP extrait par le compilateur :**
  - Ordonnancement des instructions
  - Allocation de registres
  - Construction de traces, *superblock*
  - Pipeline logiciel
- **Très utilisés dans l'embarqué**
  - Qualcomm Hexagon

Références : Hwu1993, Mahlke1992, Pinter1993, Heydemann2006

# Synthèse



- **Processeur OoO :**

- Ordonnancement dynamique
- Consommation énergétique élevée
- ISA séquentiel

- **Processeur VLIW :**

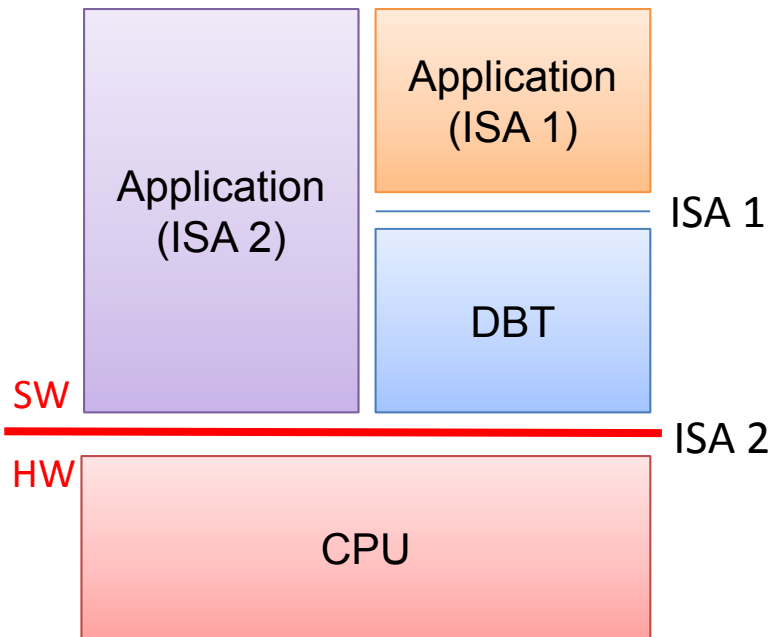
- Ordonnancement statique
- Efficacité énergétique
- ISA explicitement parallèle

# Plan de la présentation

- **Etat de l'art**
  - Architecture des processeurs
  - Traduction Dynamique de Binaires
- **Accélération matérielle de la DBT**
- **Conclusion**



# Traduction dynamique de binaires

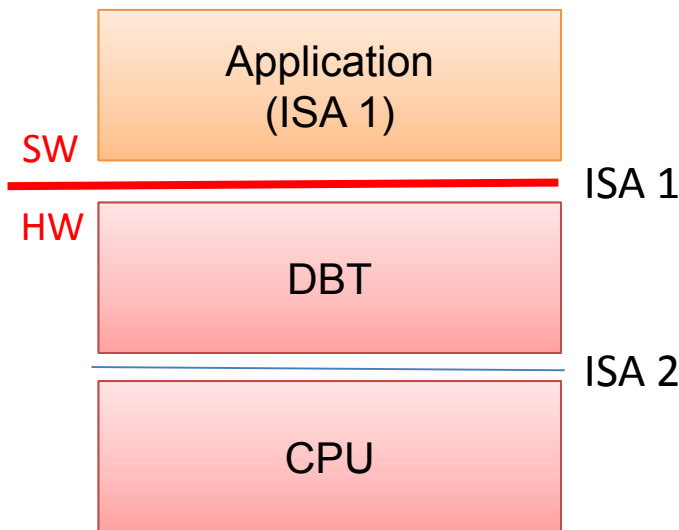


- **Principe de la DBT :**
  - Traduction d'une application compilée pour un ISA 1 vers un ISA 2
- **Objectifs usuels :**
  - **Simulation rapide** (Qemu)
  - **Compatibilité binaire** (Apple Rosetta)
- **DBT pour VLIW**
  - IBM Daisy
  - Intel IA32 Execution Layer

Références : *Bellard2005, Ebcioğlu97, Baraz2003*

# HW/SW co-designed machines

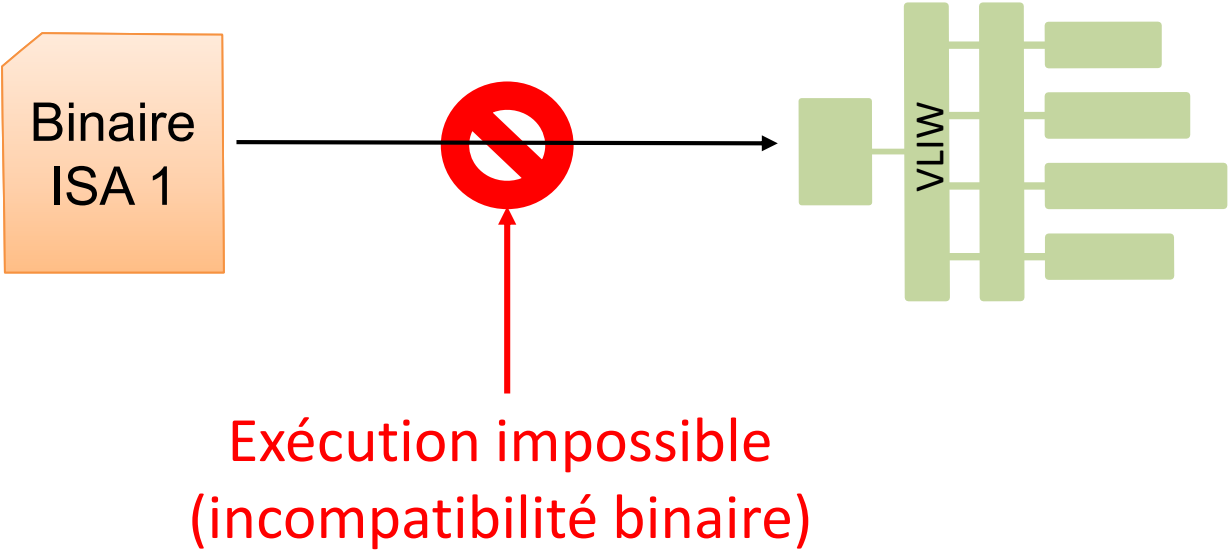
- Compatible ISA 1
- ISA 2 non exposé à l'utilisateur
- Objectif : **performances**
- Exemples :
  - micro-code Intel (x86 -> RISC)
  - Transmeta CMS (x86 -> VLIW)
  - Nvidia Denver (Arm -> VLIW)



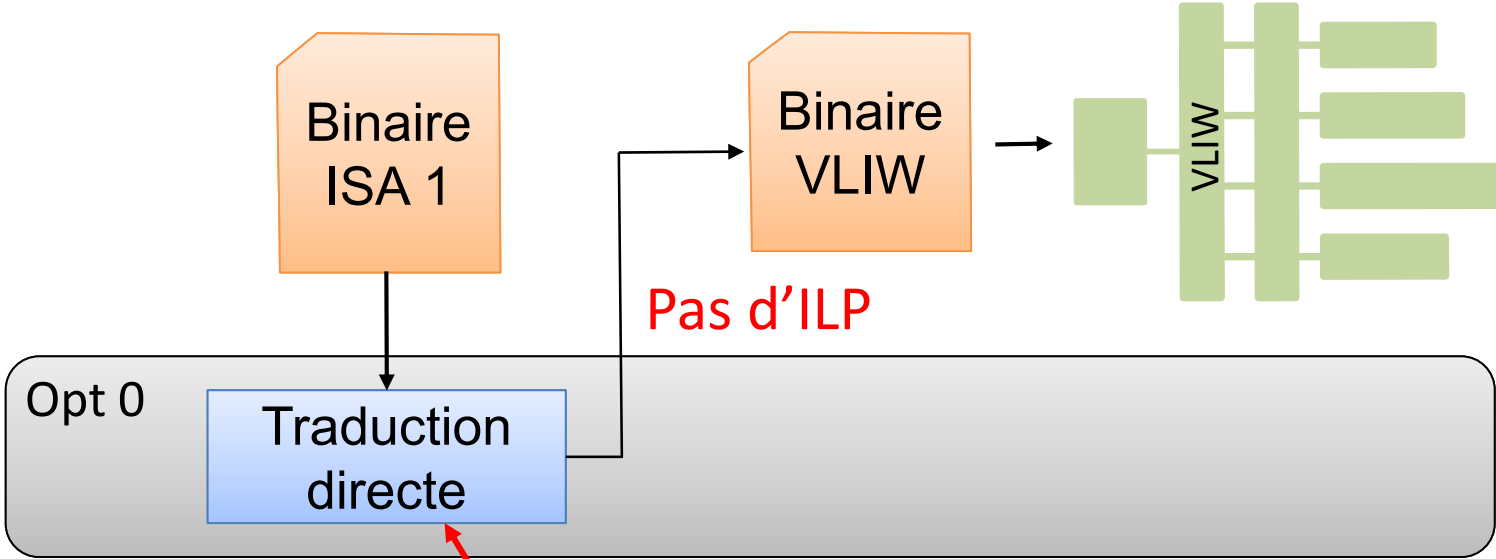
**La performance et la qualité de la DBT sont critiques**

Références : Dehnert2003, Boggs2015

# Enjeux de la traduction

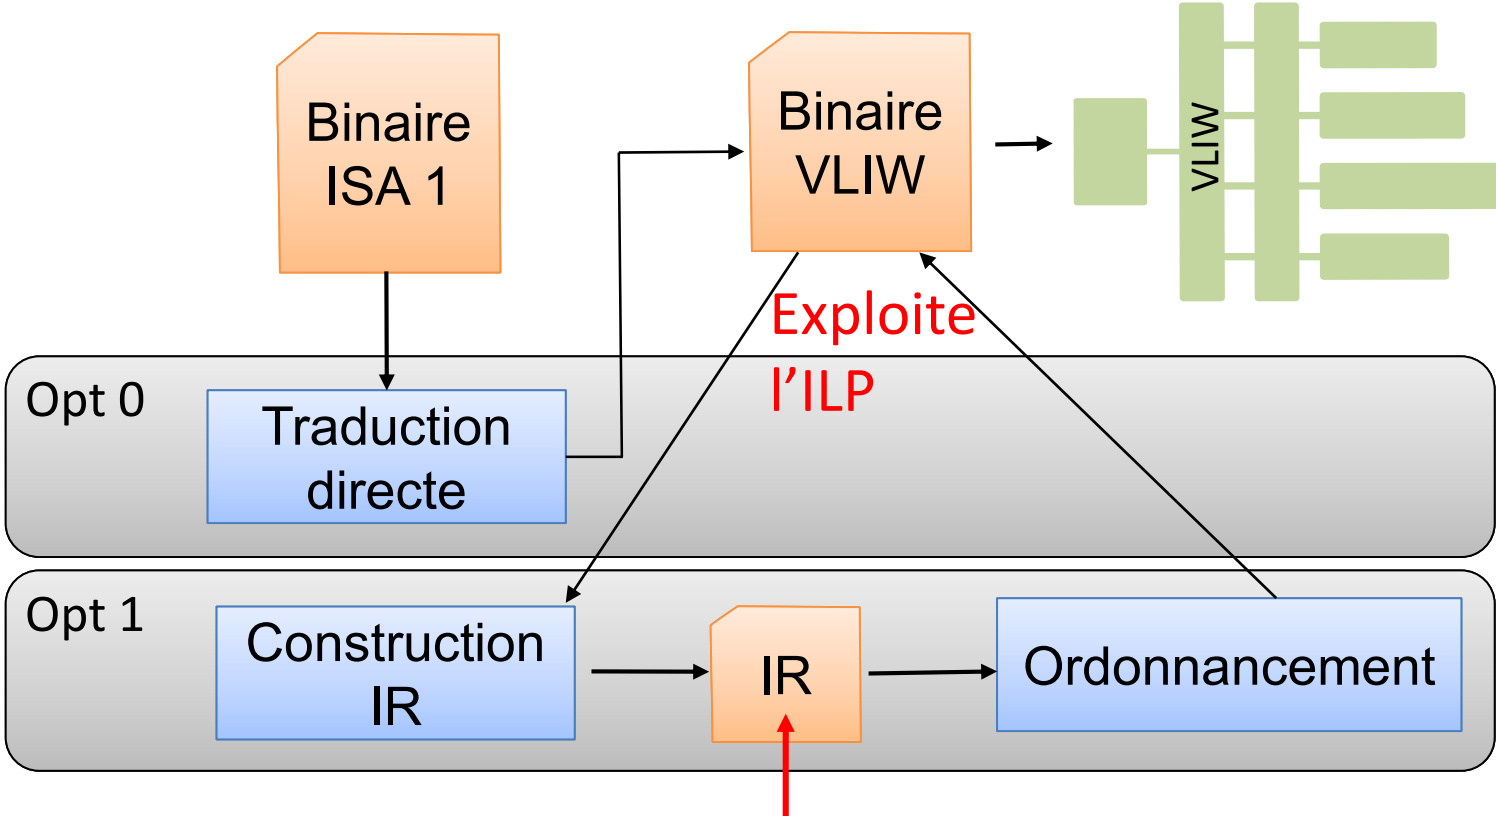


# Enjeux de la traduction



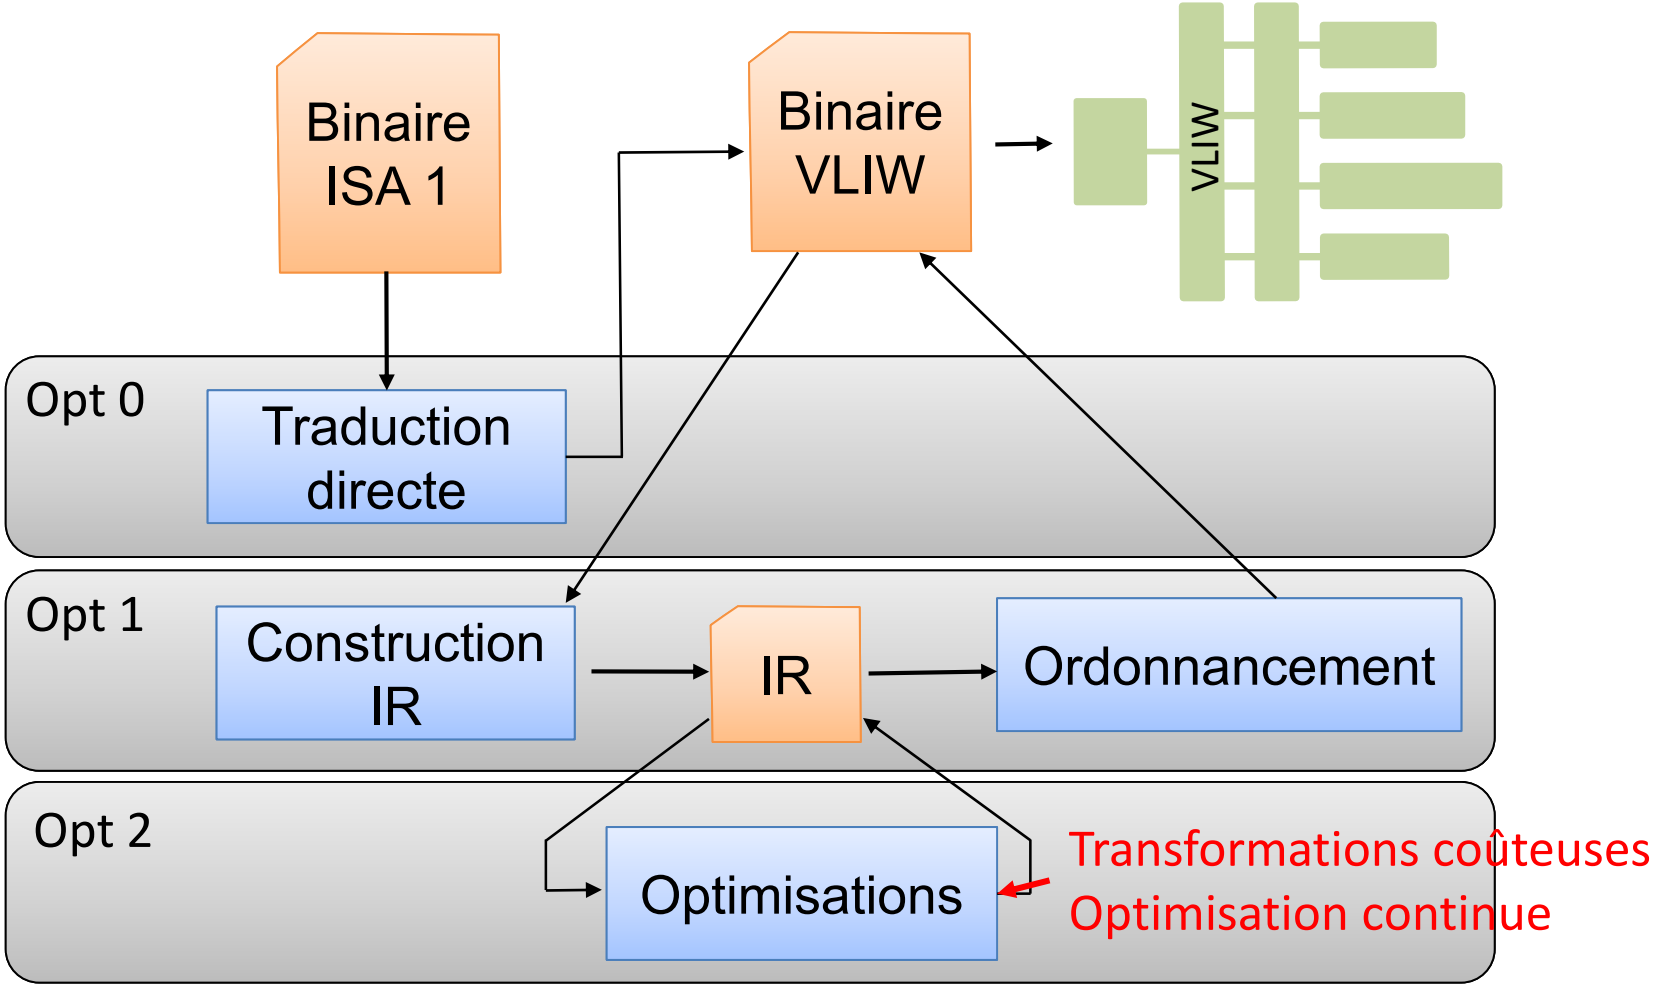
Traduction rapide ou interprétation.

# Enjeux de la traduction



Représentation intermédiaire  
de plus haut-niveau

# Enjeux de la traduction



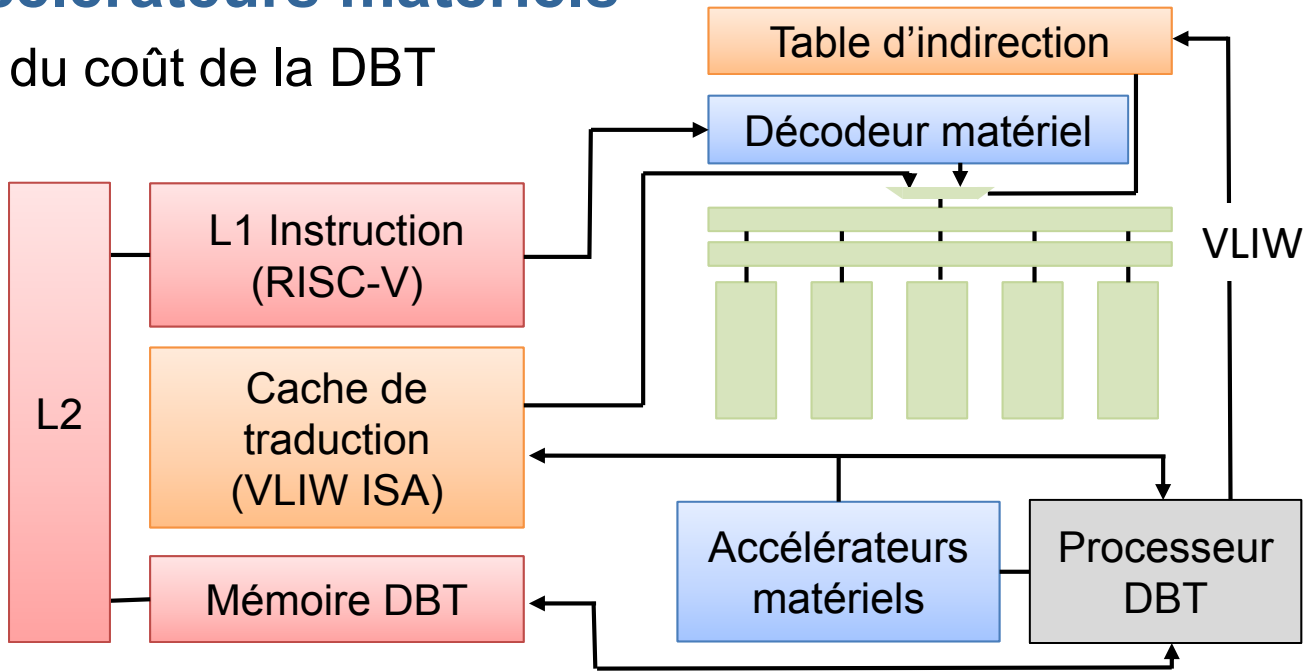
# Plan de la présentation

- **Etat de l'art**
  - Architecture des processeurs
  - Traduction Dynamique de Binaires
- **Accélération matérielle de la DBT**
- **Conclusion**

# Notre approche

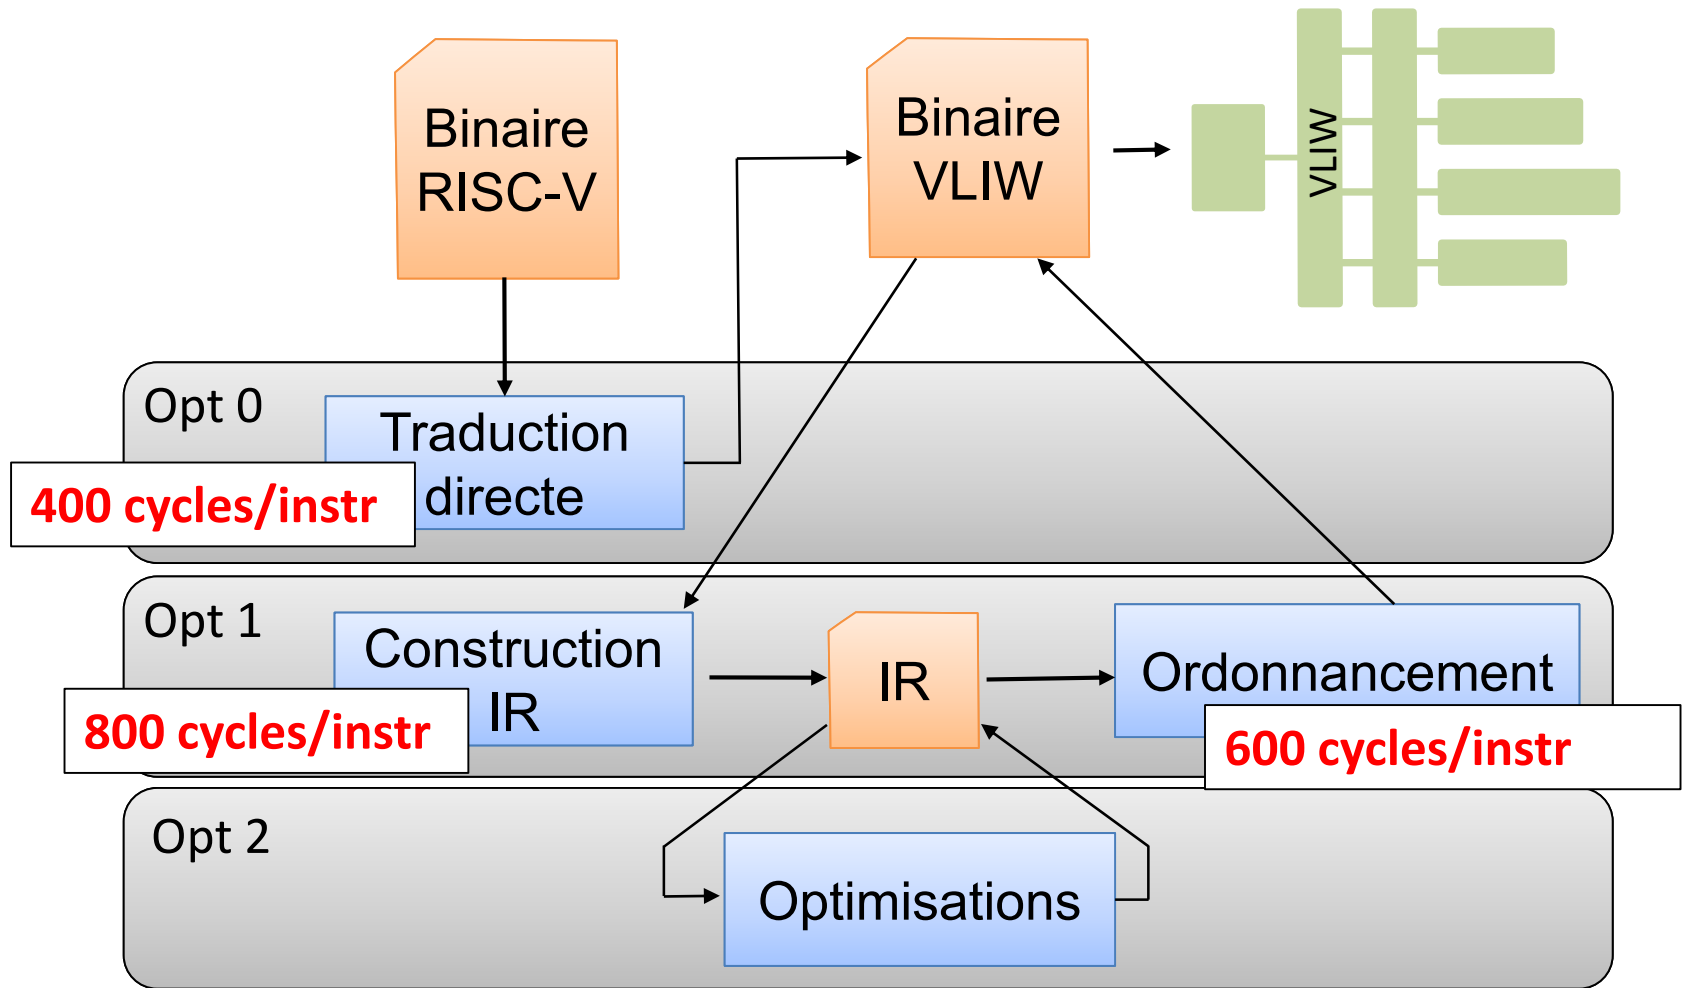


- **RISC-V vers VLIW**
- **Ajout d'un processeur dédié à la DBT**
  - Optimisation en parallèle de l'exécution
  - Optimisation en avance de phase
- **Ajout d'accélérateurs matériels**
  - Réduction du coût de la DBT

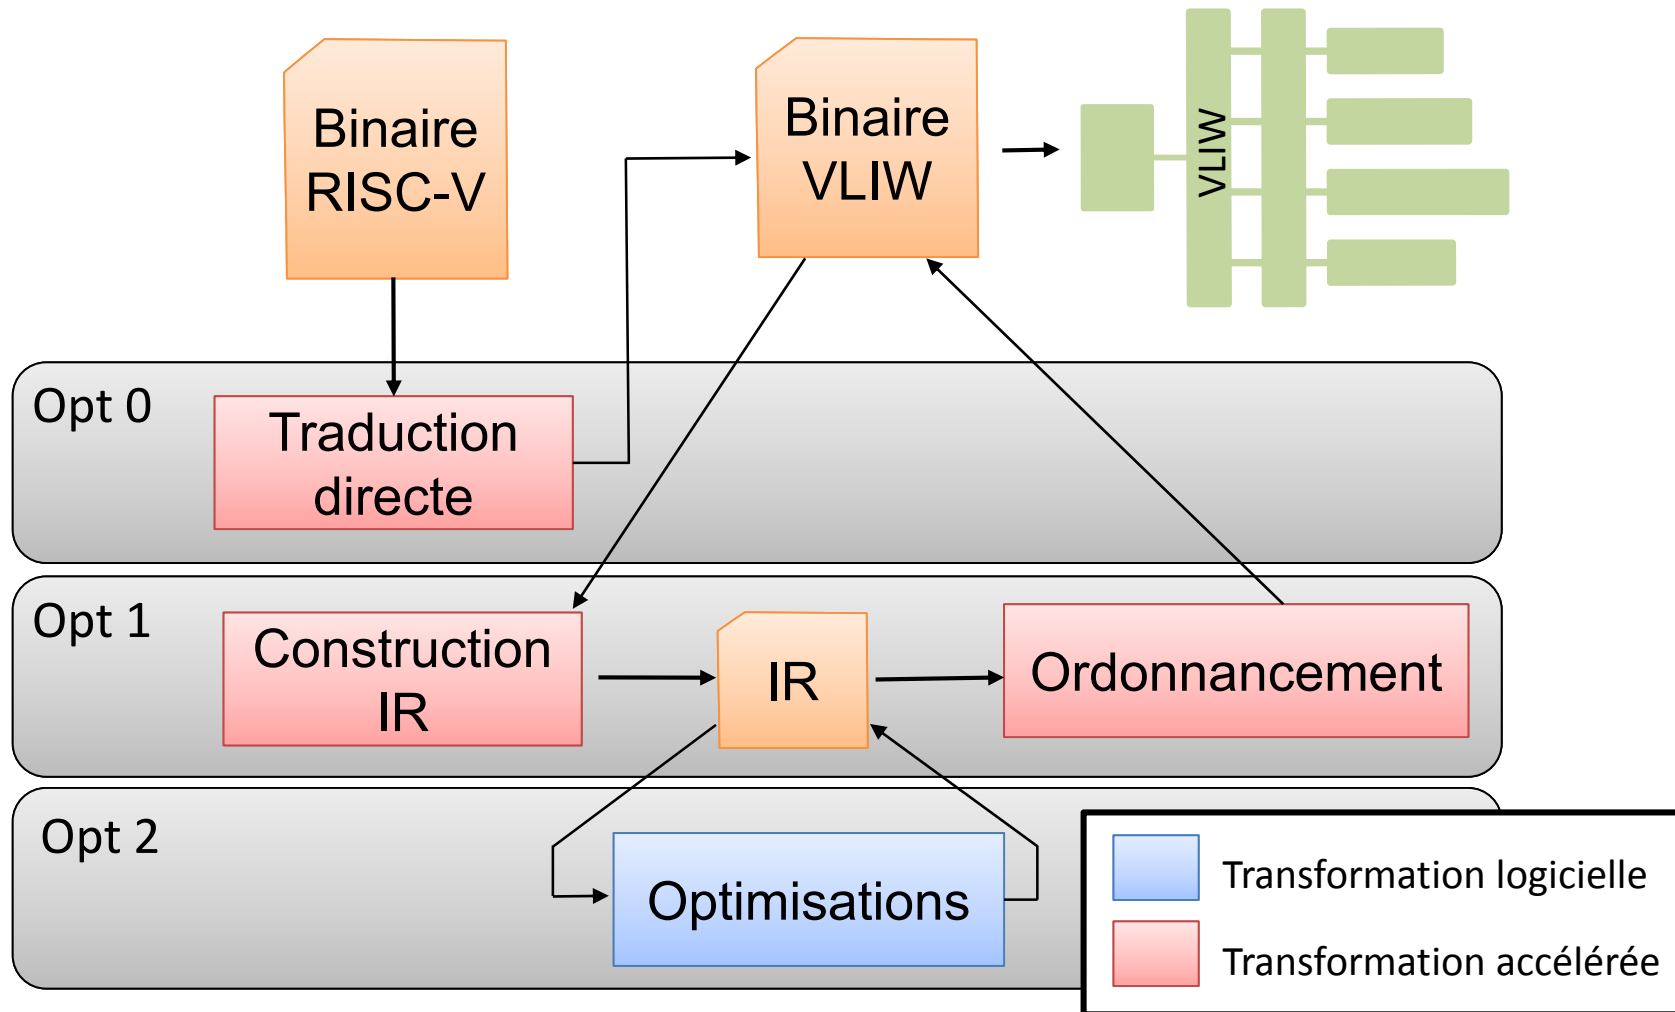




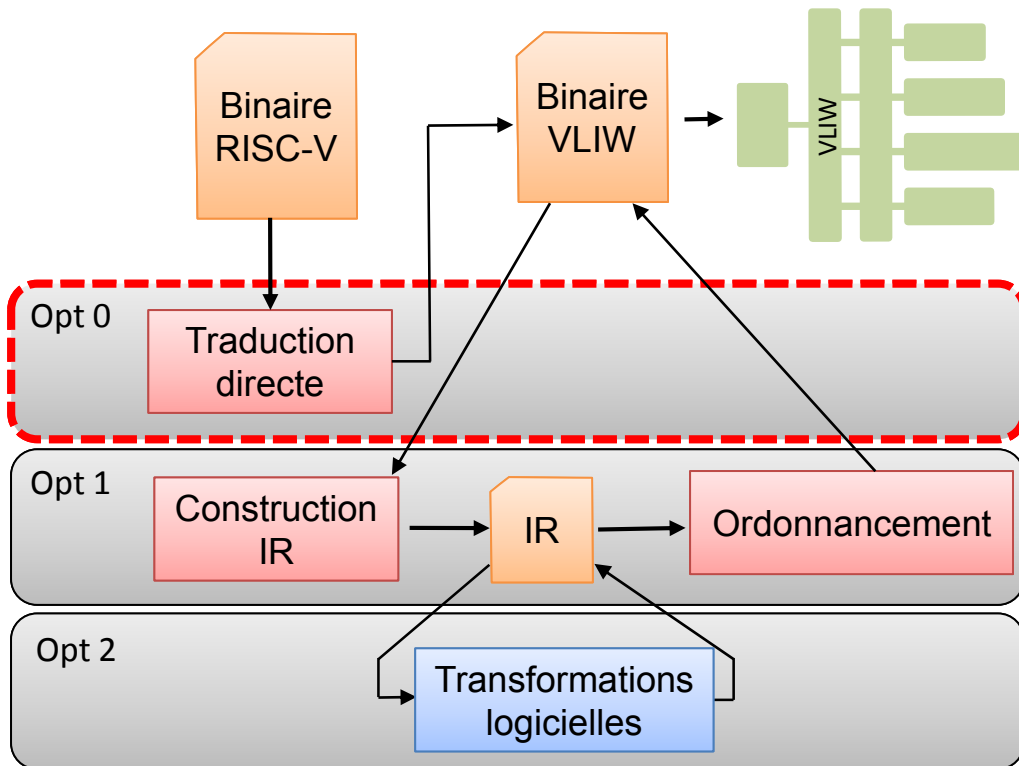
# Qu'est-ce qui doit être accéléré ?



# Qu'est-ce qui doit être accéléré ?

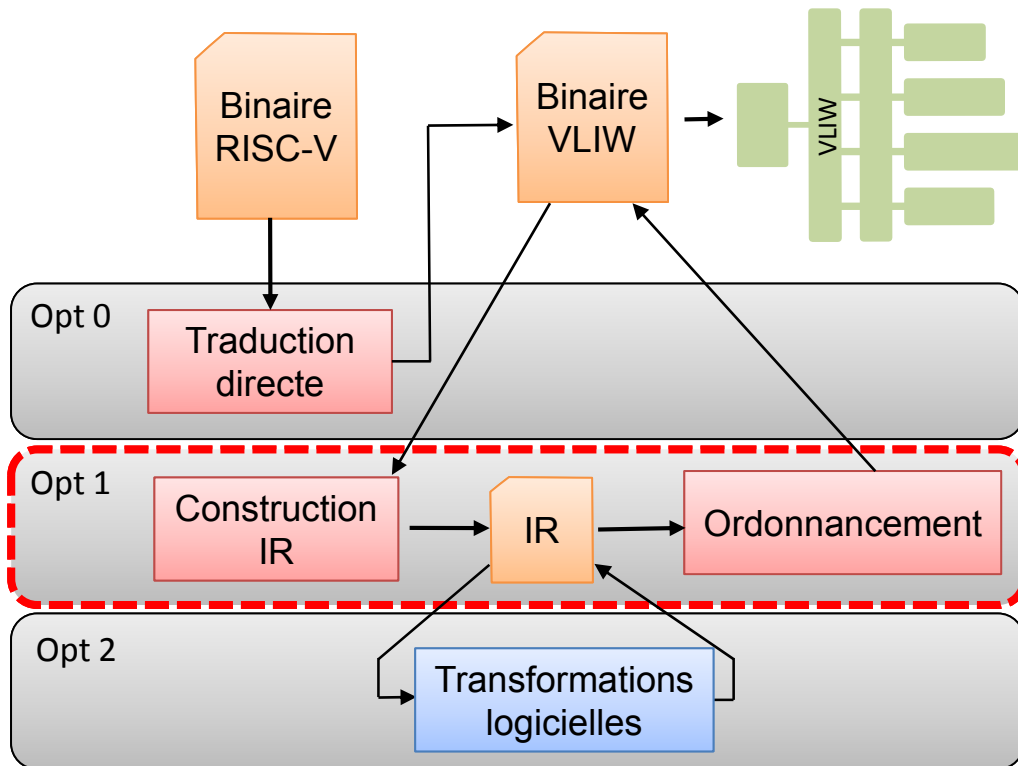


# Niveau d'optimisation 0



- Traduction individuelle de chaque instructions
- Jeux d'instructions similaires

# Niveau d'optimisation 1



- Construction du graphe de flot de données
- Ordonnancement des instructions
- Renommage des registres

# Représentation intermédiaire

## Binaire RISC-V

```
40848433 sub s0,s1,s0
0081a823 sw s0,16(gp)
00450413 addi s0,a0,4
00812023 sw s0,0(sp)
0101a403 lw s0,16(gp)
00150493 addi s1,a0,1
40848433 sub s0,s1,s0
0081a823 sw s0,16(gp)
00450413 addi s0,a0,4
00458493 addi s1,a1,4
40940533 sub a0,s0,s1
f60614e3 bnez a2,-32
00450413 addi s0,a0,4
00458493 addi s1,a1,4
40940533 sub a0,s0,s1
```

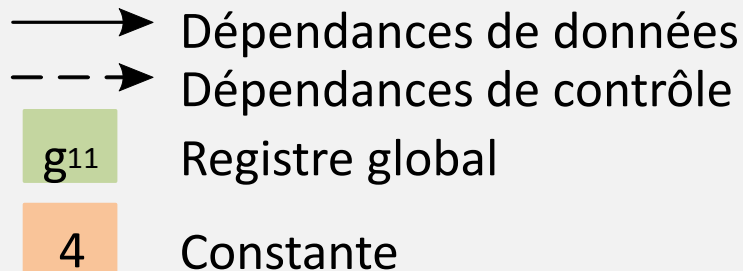
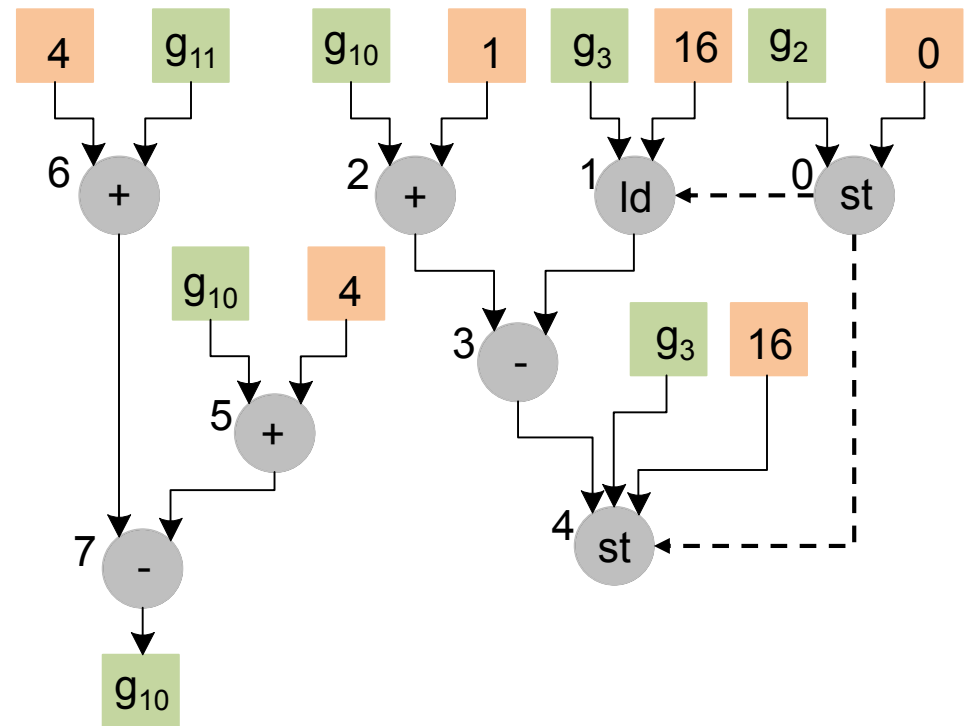
- Reconstruction du graphe de flot de contrôle
- Extraction des blocs

# Représentation intermédiaire

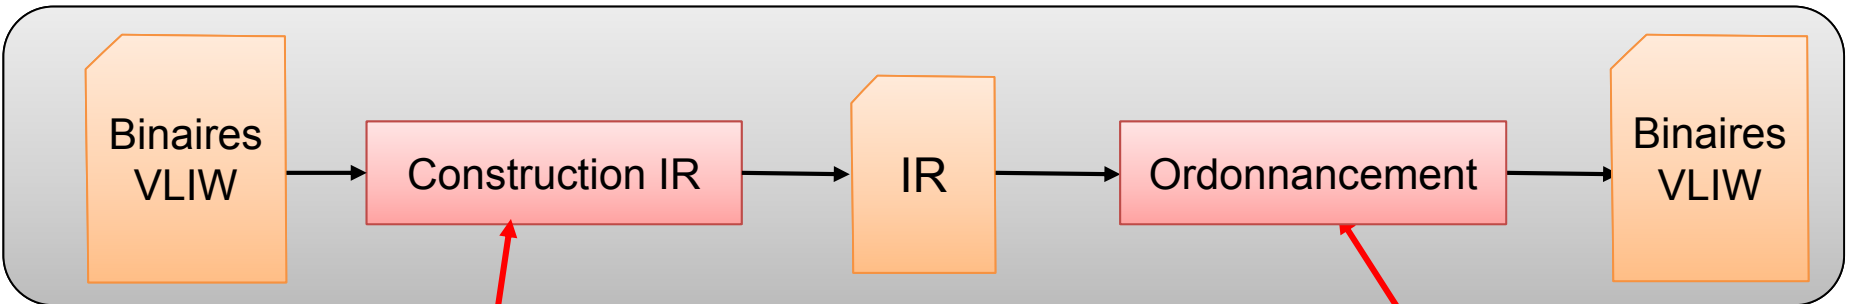
## Binaire RISC-V

```

0 - 00812023 sw s0,0(sp)
1 - 0101a403 lw s0,16(gp)
2 - 00150493 addi s1,a0,1
3 - 40848433 sub s0,s1,s0
4 - 0081a823 sw s0,16(gp)
5 - 00450413 addi s0,a0,4
6 - 00458493 addi s1,a1,4
7 - 40940533 sub a0,s0,s1
    
```




# Chaîne de compilation en matériel



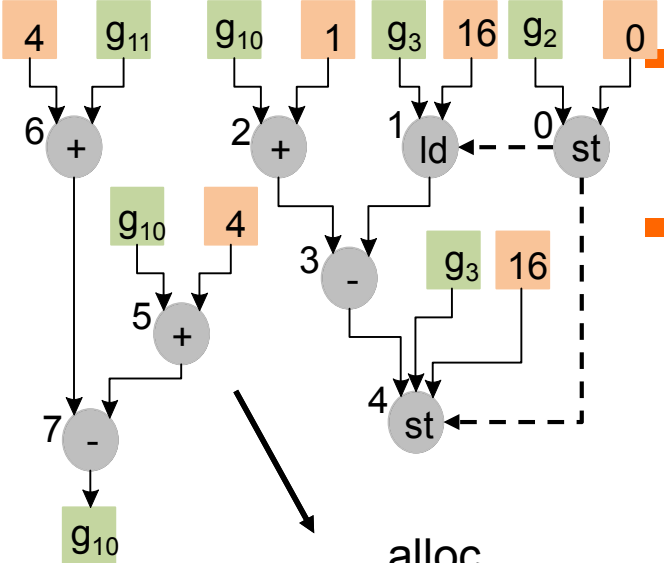
Analyse en une passe

Ordonnancement *scoreboard* & support pour le renommage



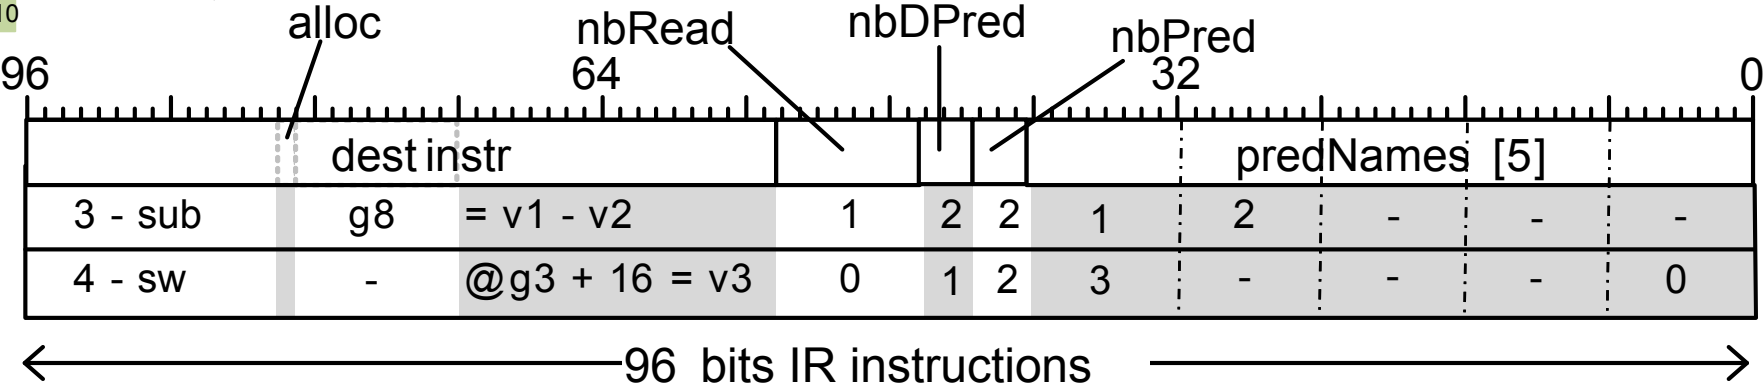
- Trop complexe à développer en HDL
- Utilisation de la **Synthèse de Haut-Niveau**
  - Déroulage / Pipeline de boucles
  - Partitionnement mémoire
  - Factorisation des accès mémoire
  - *Forwarding* explicite

# Représentation intermédiaire



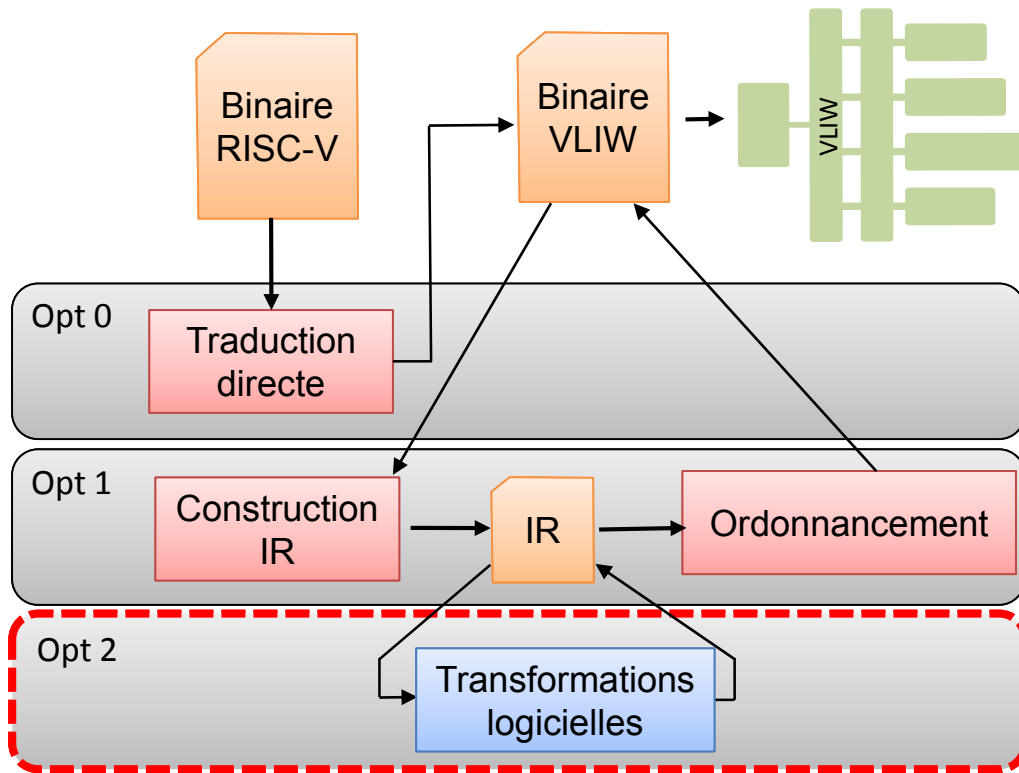
**Grphe de flot de contrôle encodé dans l'IR**

- Informations sur l'allocation de registres





# Niveau d'optimisation 2




- **Optimisations logicielles**
- **Optimisation continue**
  - Reconfiguration dynamique du VLIW
  - Spéculation de dépendances mémoire

# Etude expérimentale

- **Objectifs de l'étude :**
  - Impact des accélérateurs sur le coût de la DBT
  - Impact des accélérateurs sur la performance du système
  - Comparaison de notre approche avec OoO et inO
  - Coût matériel
  
- **Protocole expérimental**
  - Cible : **28nm**,  $f_{max}$  : **700MHz**
  - Performance : Gem5, Hybrid-DBT (cycle accurate)
  - Consommation : Simulation *gate-level* avec traces

# Performance des accélérateurs

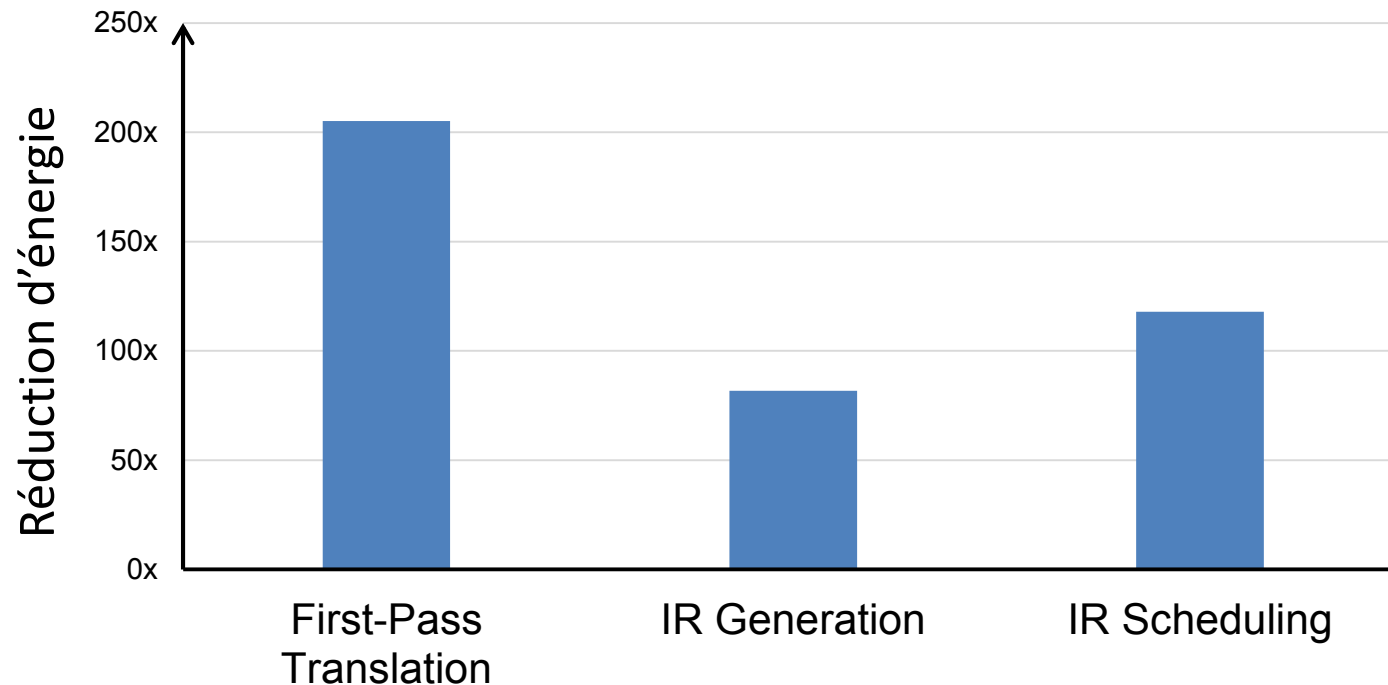
- **Impact des accélérateurs sur le temps de DBT**
  - Facteur d'accélération comparé à une solution logicielle sur le processeur DBT



# Consommation des accélérateurs


## Impact des accélérateurs sur l'énergie de la DBT

- Facteur de réduction d'énergie comparé à une solution logicielle sur le processeur DBT




# Intérêt de l'accélération matérielle

- Impact des accélérateurs sur le **temps d'exécution** d'une application




# Intérêt de l'accélération matérielle

- Impact des accélérateurs sur l'énergie consommée par une application




# Performance du système

- Comparaison des performances de Hybrid-DBT, d'un inO et d'un OoO



# Efficacité énergétique du système


- Comparaison de l'efficacité énergétique de Hybrid-DBT, d'un inO et d'un OoO






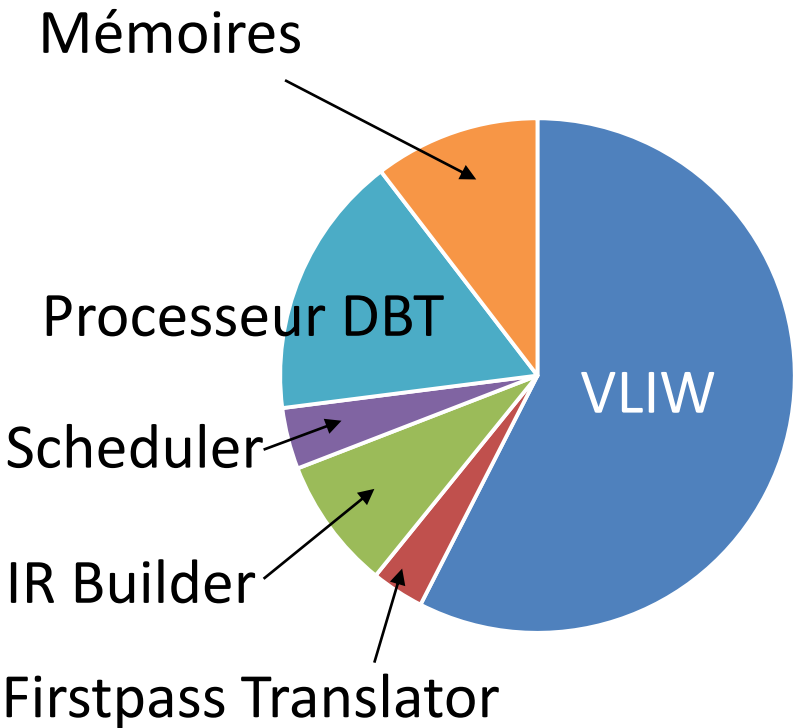
# Efficacité énergétique du système

- Comparaison de l'efficacité énergétique de Hybrid-DBT, d'un inO et d'un OoO



# Surcoût matériel

- Coût matériel de notre approche



# Plan de la présentation

- **Etat de l'art**
  - Architecture des processeurs
  - Traduction Dynamique de Binaires
- **Accélération matérielle de la DBT**
- **Conclusion**

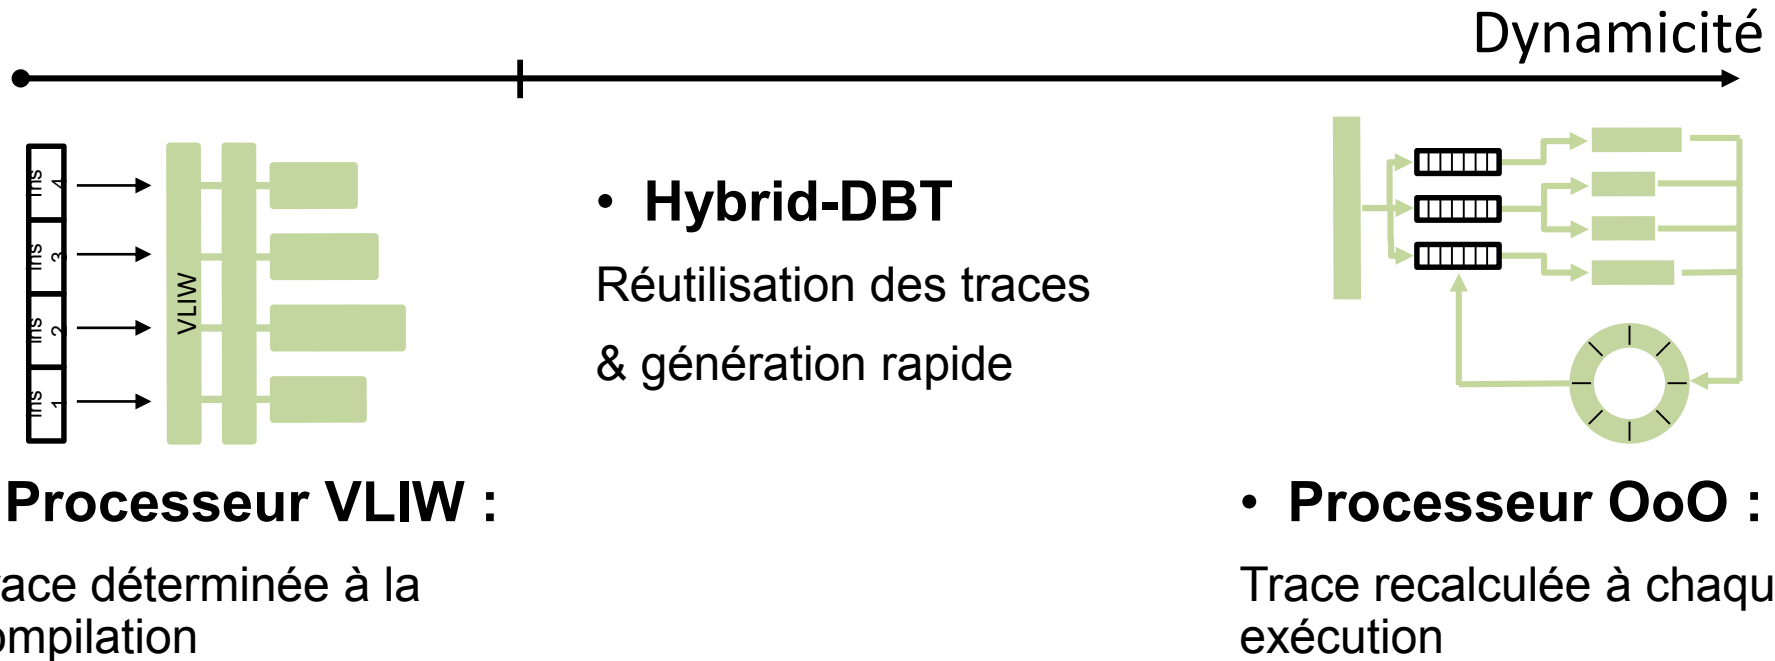
# Conclusion

- **Conception d'une *HW/SW Co-Designed Machine***
  - Mise en place du flot d'optimisation
  - Définition de l'IR
  - Conception conjointe de quatre accélérateurs
  - Conception du processeur VLIW en HLS
  
- **Optimisation continue**
  - Spécialisation dynamique du VLIW
  - Spéculation de dépendances mémoire
    - Conception d'une LSQ partitionnée
    - Gestion de la spéculation dans l'ordonnanceur

# Perspectives – Construction de traces

## ■ Réduction du coût de la construction de traces

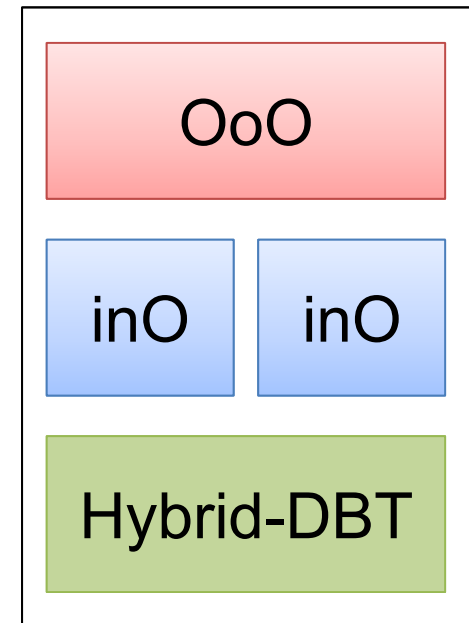
- Mécanisme similaire aux prédicteurs de branchements
- Ordonnanceur avec support pour la spéculation



# Perspectives – Système hétérogène

- **Intégration dans un système hétérogène**
  - Processeurs OoO
  - Processeurs inO
  - Hybrid-DBT
- **Politique de migration de tâches**
- **Utilisation des compteurs de performances**

Système



# Perspectives - Sécurité

- **Spéculation lors des phases d'optimisation**
- **Sensible aux failles spectres**
  - Construction de traces : *Bounds Check Bypass* (v1)
  - Spéculation mémoire : *Speculative Store Bypass* (v4)
- **Modification du flot de DBT pour prévenir ces attaques**

