Compilation efficace d'applications de traitement d'images pour processeurs manycore

CEA LIST, Saclay

Pierre Guillou

mardi 6 décembre 2016

MINES ParisTech, PSL Research University

Évolution des capacités de calcul

1987

2000

2016

De nouvelles architectures

Limitations des processeurs monocœurs

- fréquence d'horloge — bloquée depuis 2005
- consommation d'énergie — systèmes embarqués
- utilisation efficace des transistors ?

Nouvelles architectures parallèles

- processeurs multicœurs — jusqu'à 10 cœurs…
- GPGPUs — SIMD, 30 — 4000 cœurs
- processeurs *manycores* — 60 — 300 cœurs

> *The free lunch is over. Now welcome to the hardware jungle.*
>
> — Herb Sutter, 2011

Les processeurs *manycore* : le MPPA de Kalray

256 cœurs de calcul, 10 W

2 générations : Andey (400 MHz), Bostan (600 MHz)

L'architecture du processeur MPPA

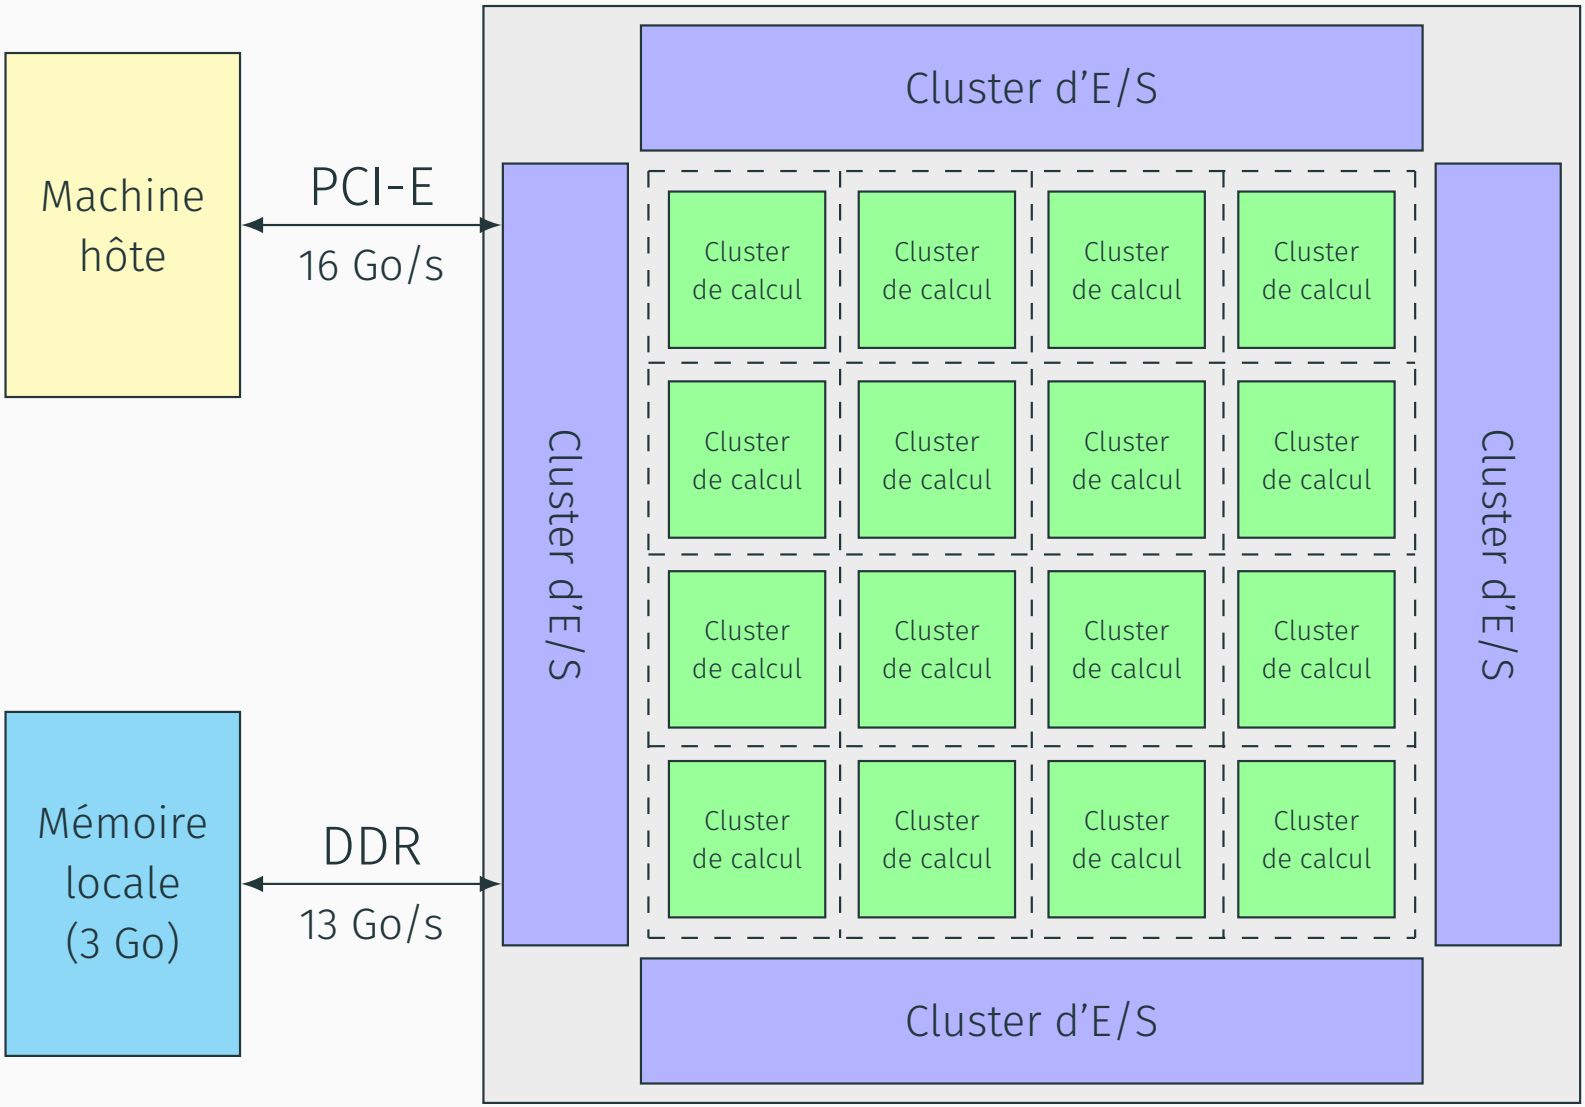

16 clusters × (16 cœurs + 2 Mo)

Le traitement d'images, un domaine innovant et dynamique

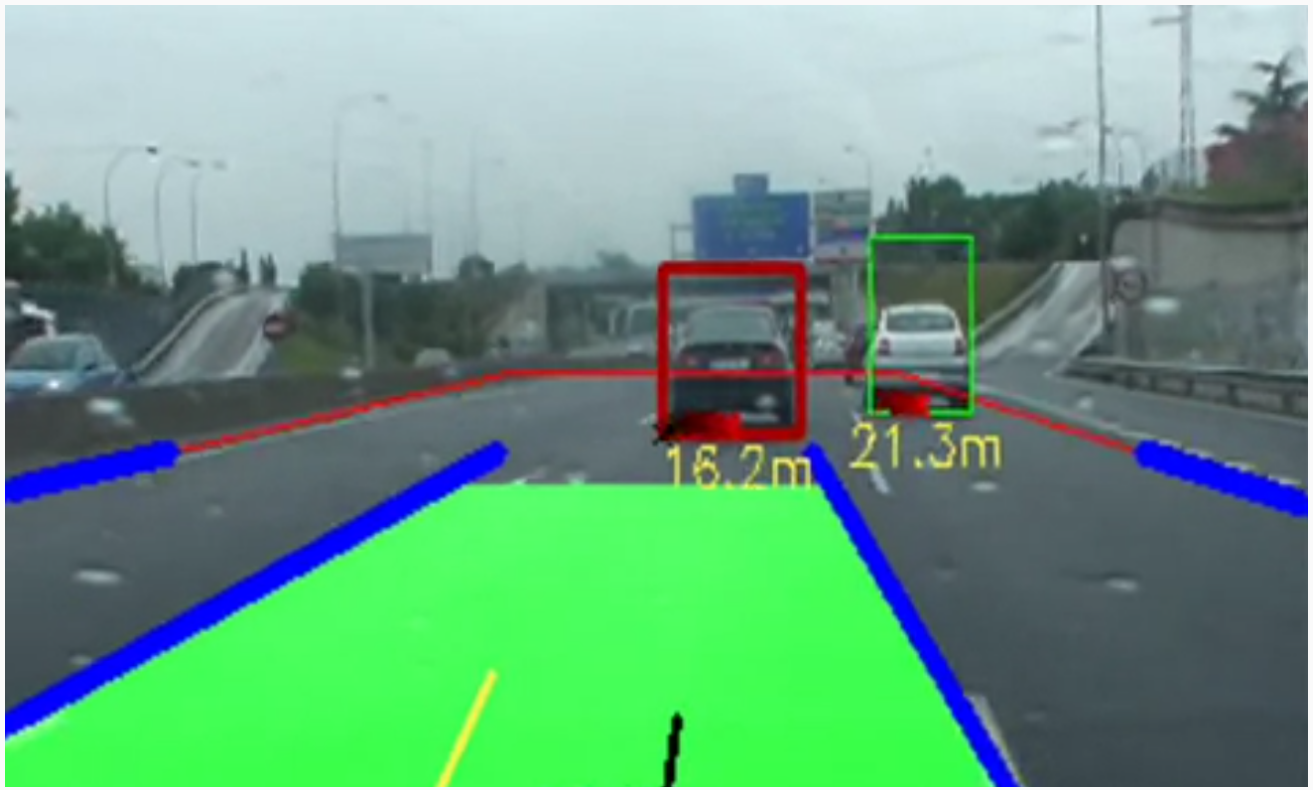

Une branche : la *morphologie mathématique*

Propriétés géométriques

- détection, extraction

Algèbre d'opérateurs images

- réguliers, parallèles
- arithmétiques
  unaires & binaires
- « morphologiques »
  érosion, dilatation, convolution
- réductions
  min, max, somme

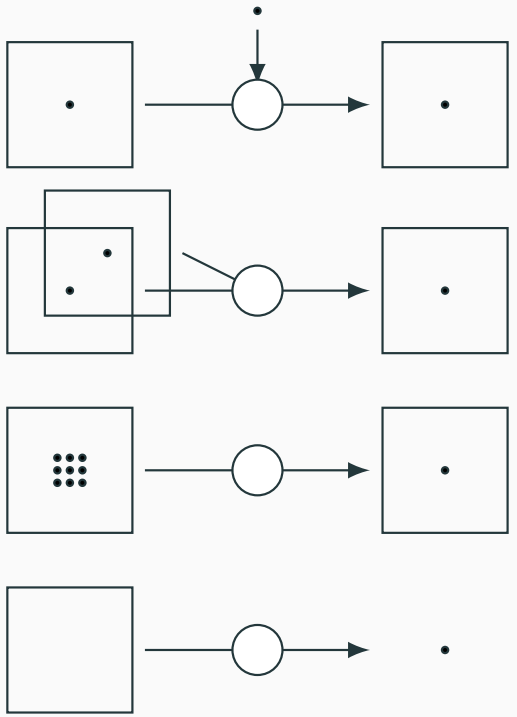

licensePlate : détection de plaque d'immatriculation

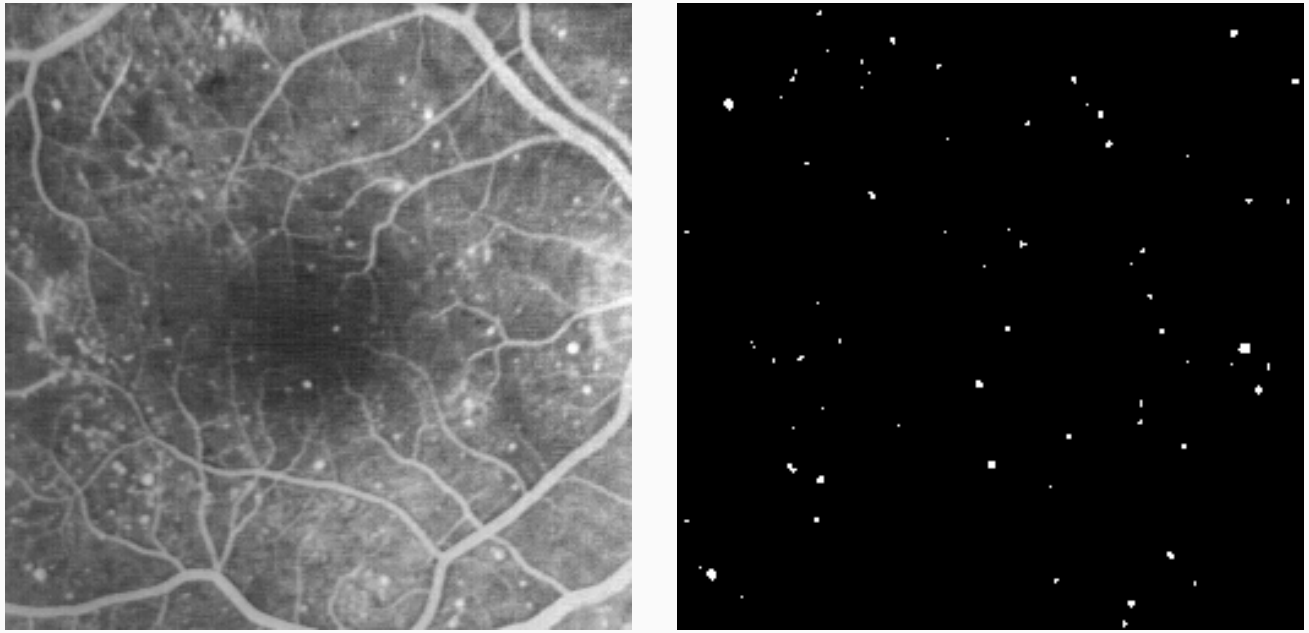

retina : détection des lésions de la rétine

Difficultés du développement logiciel

Applications $\longrightarrow$ matériels

• fonctionnalités	temps de développement
• matériels cibles	travail de portage
• optimisations	fluidité, temps de réponse, autonomie

Enjeux : les *3P*

• programmabilité	temps de développement, maintenance
• portabilité	cibles matérielles
• performance	temps d'exécution, énergie

Classes d'architectures et modèles de programmation

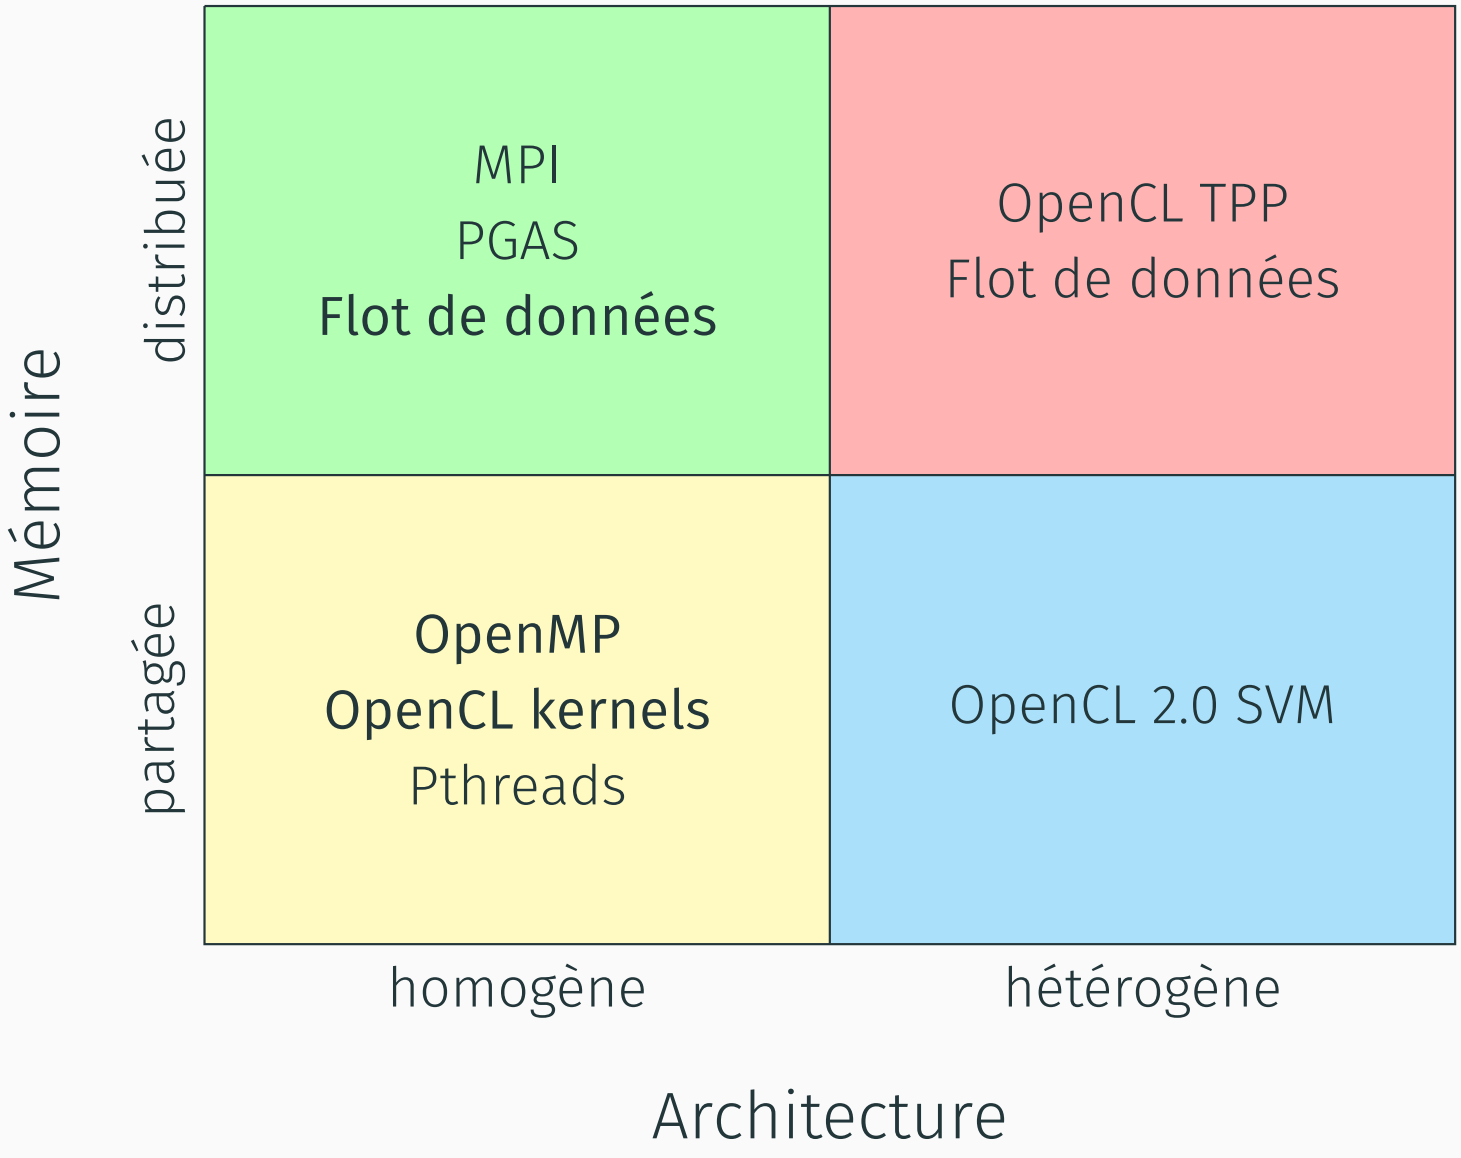

Plan

Méthodologie de recherche

Méthodologie de recherche

Sujet

- **compilation efficace** — 1 programme $\longrightarrow$ *3P*
- **traitement d'images** — utile, parallèle
- **architectures manycore** — complexité vs. énergie

Étude de cas

- le processeur manycore MPPA de Kalray
- le traitement d'images par morphologie mathématique
- des langages de traitement d'images (DSLs $\rightarrow$ *3P*)

Contributions principales

Comparaisons expérimentales sur MPPA

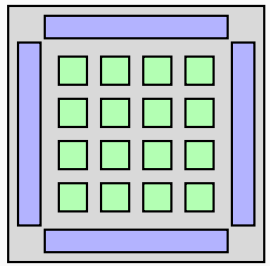

- 3 modèles de programmation parallèle
- 2 générations de processeurs

Preuve de la possibilité d'atteindre les *3P*

- développement d'un environnement logiciel intégré
- regroupant plusieurs chaînes de compilation
- restreint au traitement d'images

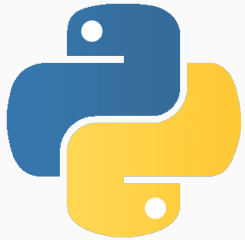

SMIL : Simple (but efficient) Morphological Image Library

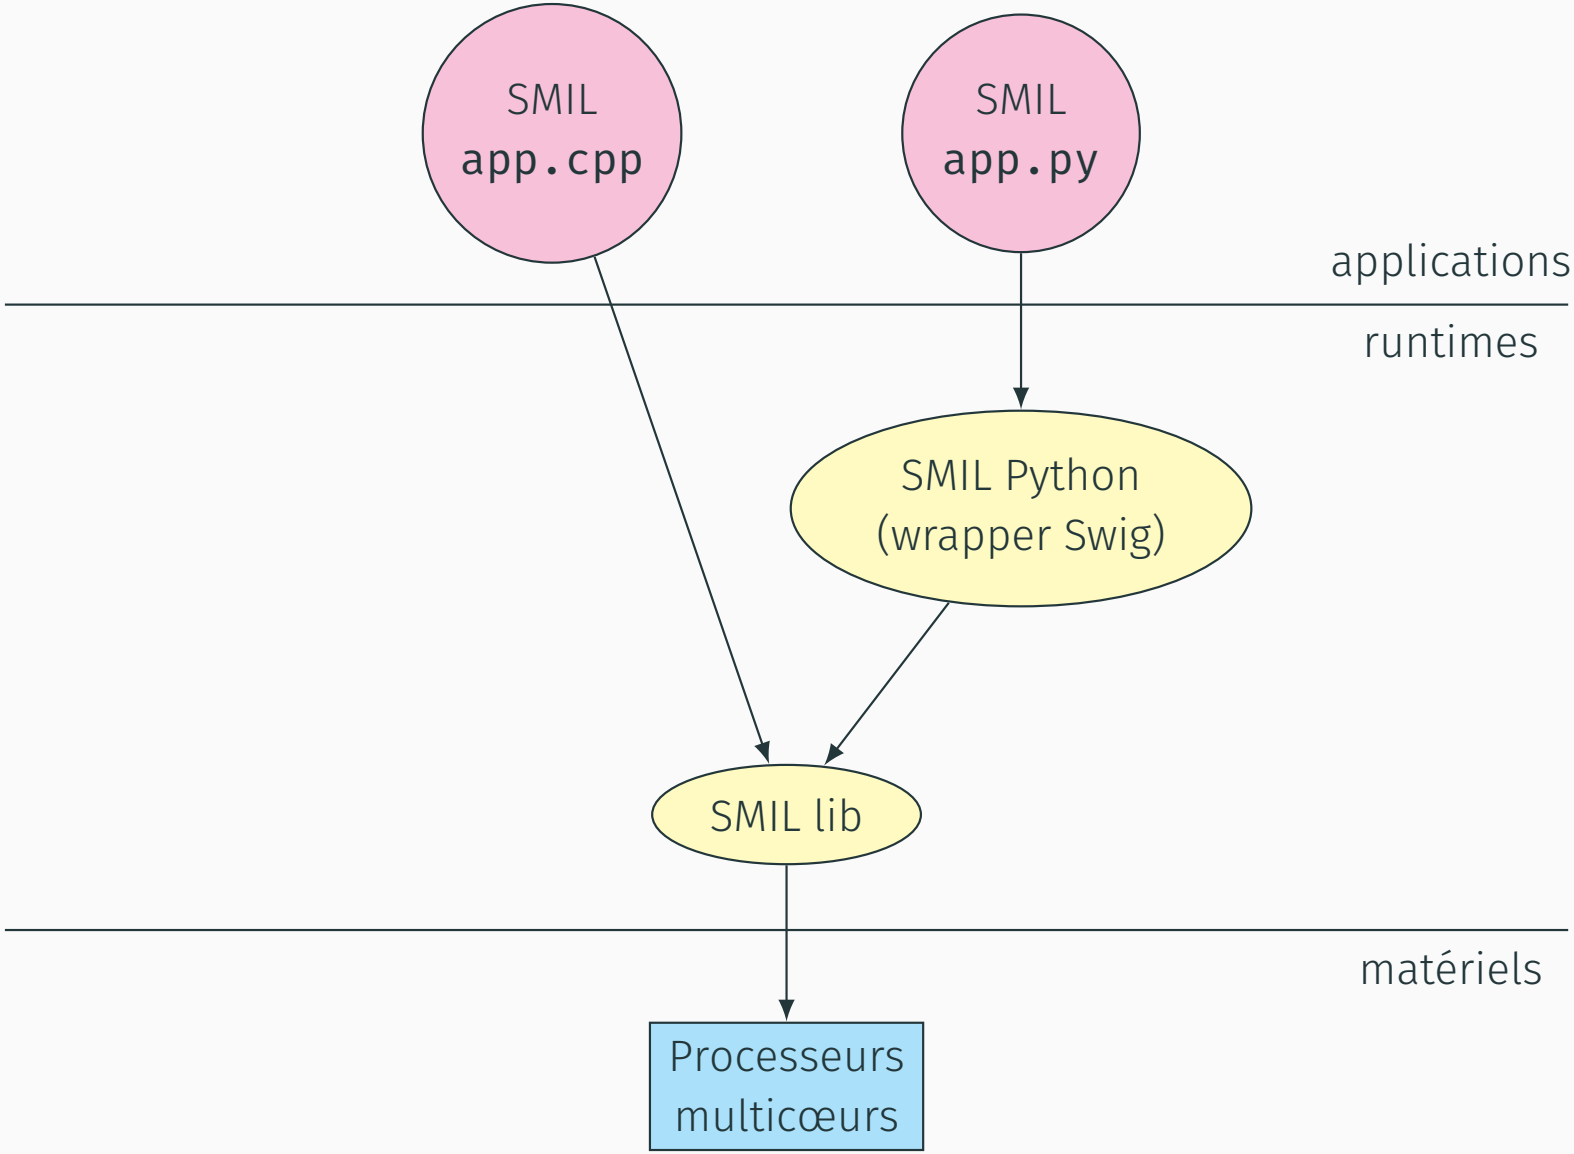

Exemple de code SMIL

```
import smilPython as smil

imin = smil.Image("input.png")  # lecture sur le disque
imout = smil.Image(imin)        # allocation de imout
smil.gradient(imin, imout)      # gradient morphologique
imout.save("output.png")        # écriture sur le disque
```

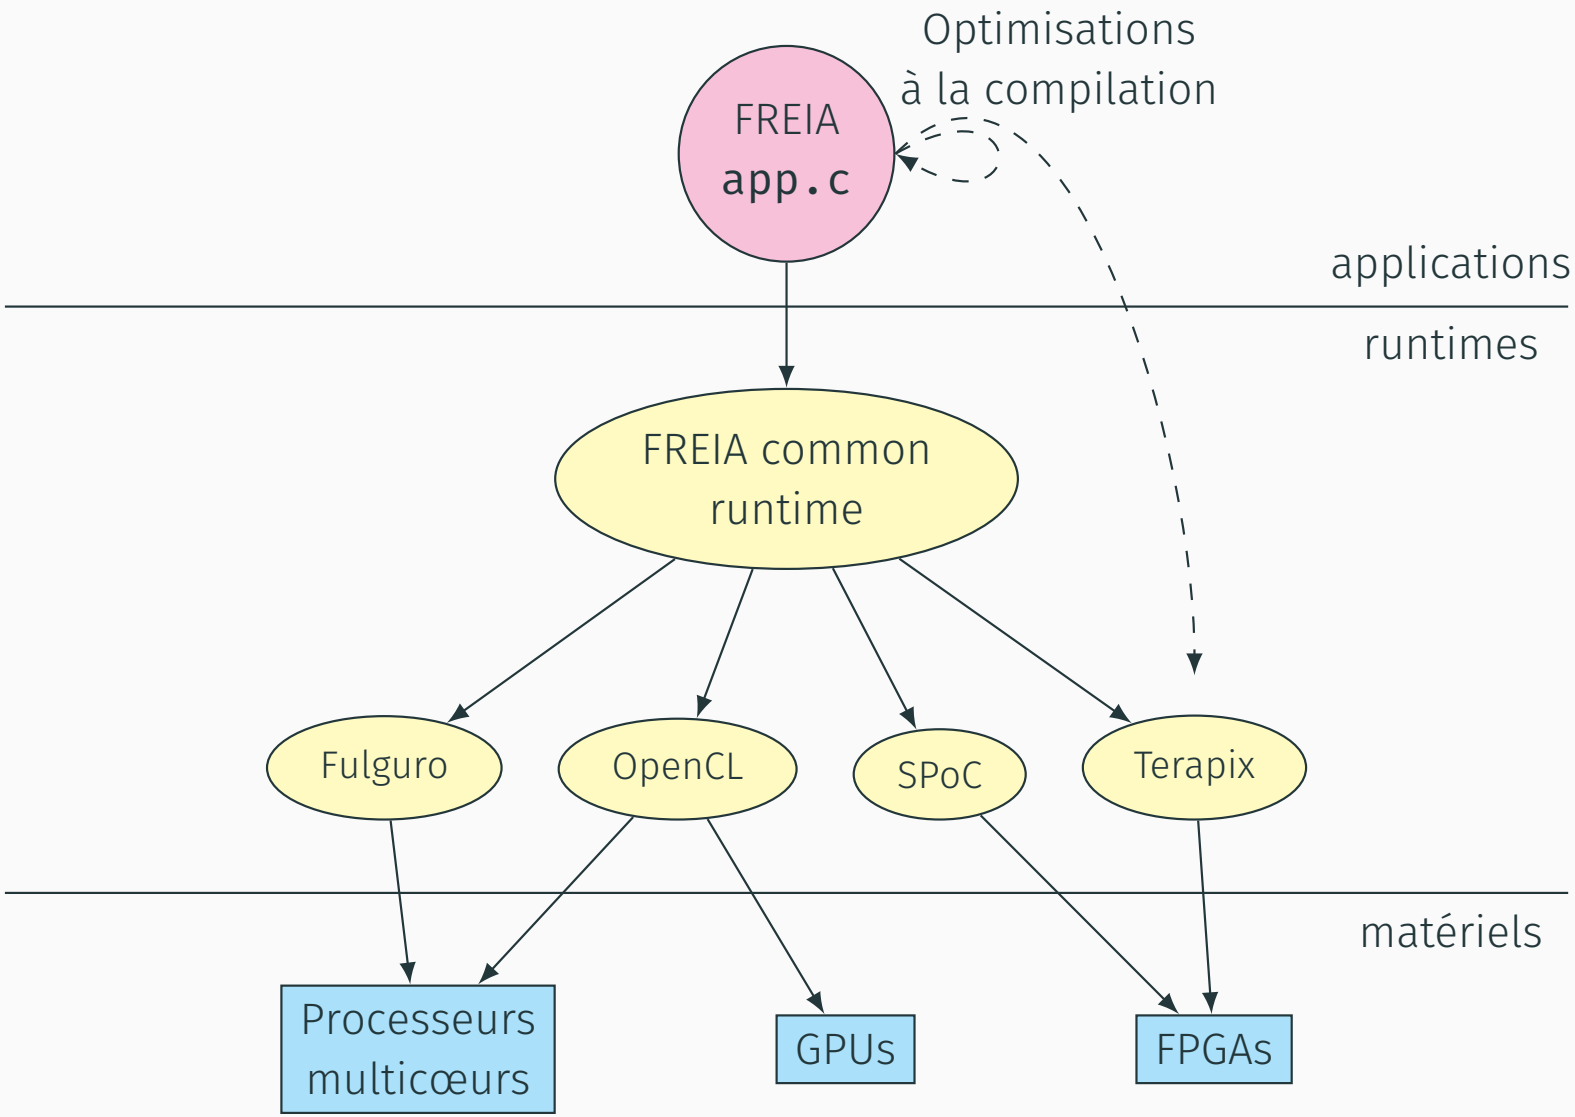
Optimisations
à la compilation
FREIA
app.c
applications
runtimes
FREIA common
runtime
Fulguro
OpenCL
SPoC
Terapix
matériels
Processeurs
multicœurs
GPUs
FPGAs

PIPS pour FREIA

Compilateur source-à-source

- entrée DSL : code C + appels FREIA
- optimisations spécifiques traitement d'images :
  - décomposition des opérateurs complexes
  - élimination des temporaires
  - élimination des sous-expressions communes
  - propagation des copies
  - fusion d'opérateurs
- sortie, génération de code :
  - FREIA simplifié
  - SPoC, Terapix (FPGAs)
  - OpenCL
  - Sigma-C

I — Le modèle OpenMP

OpenMP, un modèle pour architectures à mémoire partagée

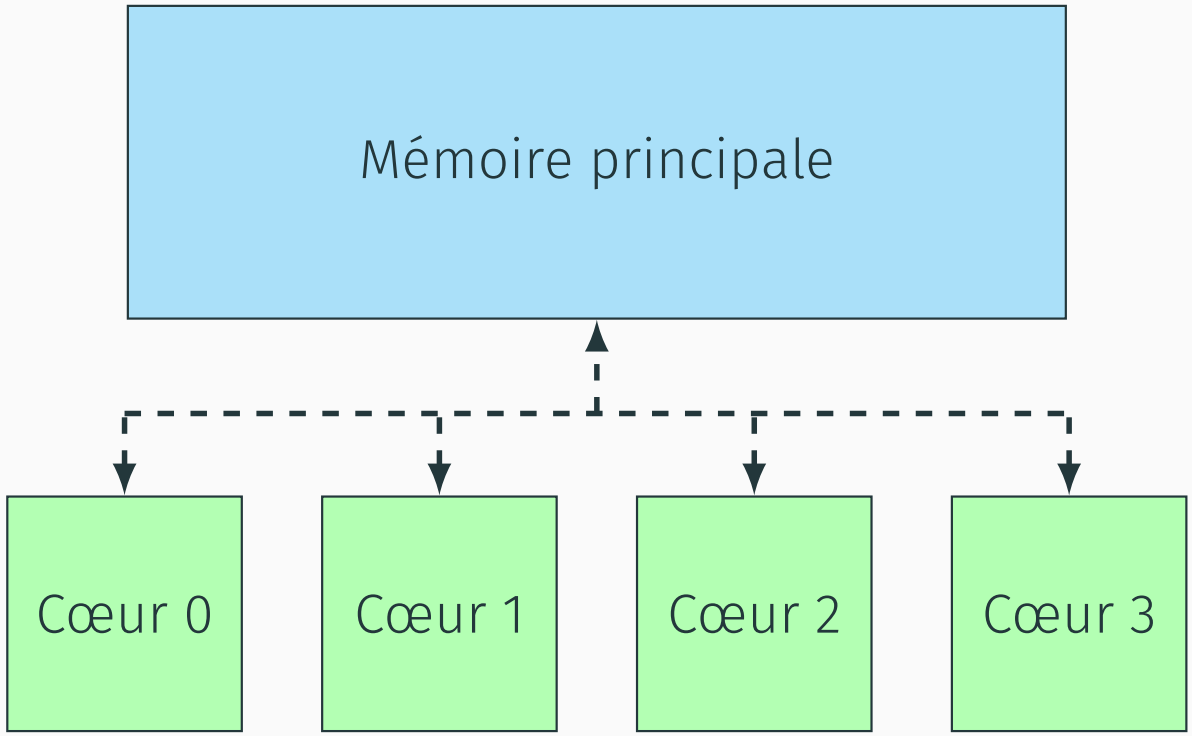

Addition de vecteurs en OpenMP

```
void vecAdd(float *a, float *b, float *c,
            const unsigned int n) {

  unsigned int i;

#pragma omp parallel for
  for (i = 0; i < n; i++)
    c[i] = a[i] + b[i];

}
```

Environnement d'exécution OpenMP : 1 cluster

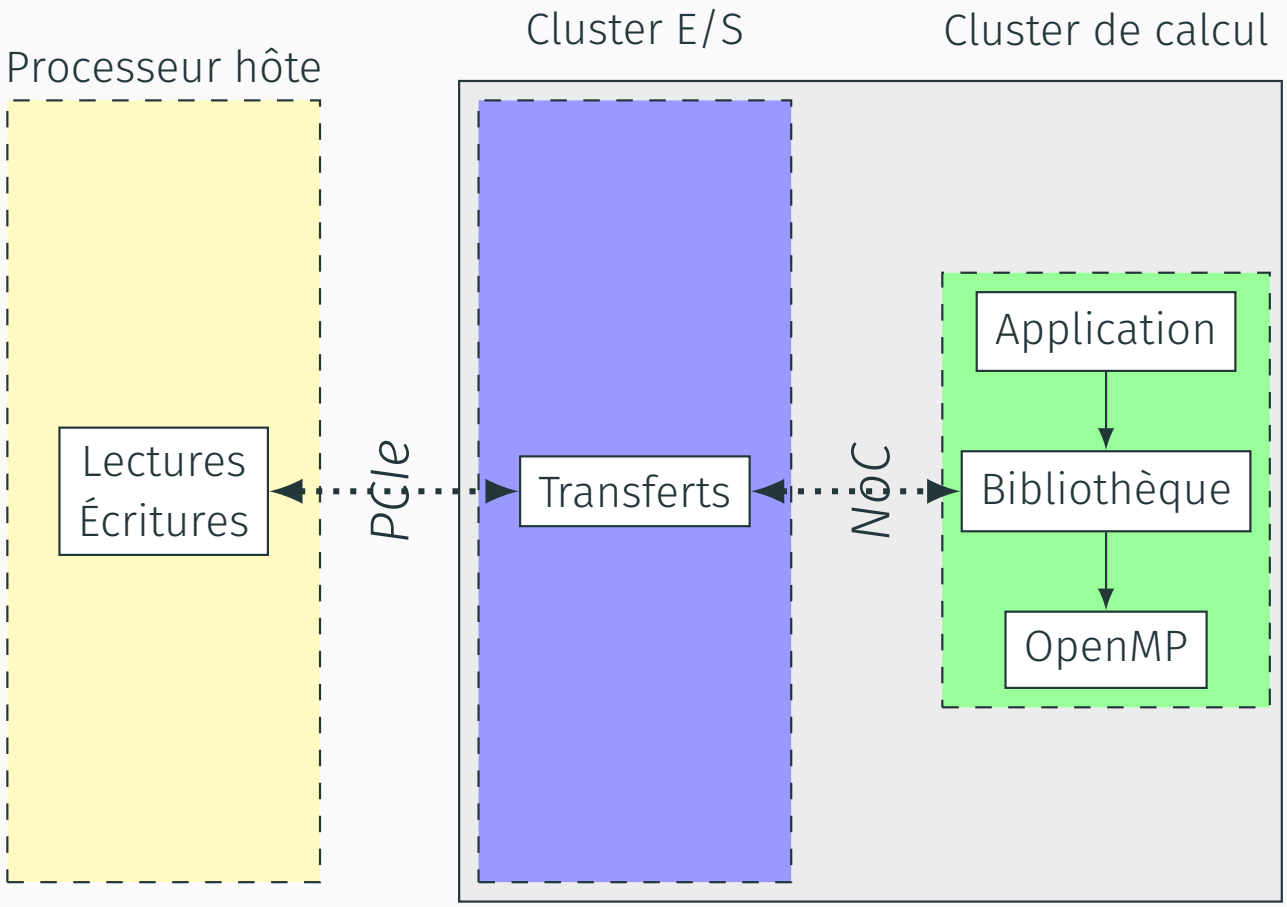

Portage SMIL sur 1 cluster MPPA

Simple* Morphological Image Library
(*but efficient)

SMIL	bibliothèque C++, OpenMP	*standard*
CMake	compilation croisée	*portage rapide*
transferts	avec l'hôte	*3 environnements*
mémoire	très limitée : 2 Mo	*imagettes*

Évaluation : passage à l'échelle de SMIL avec OpenMP

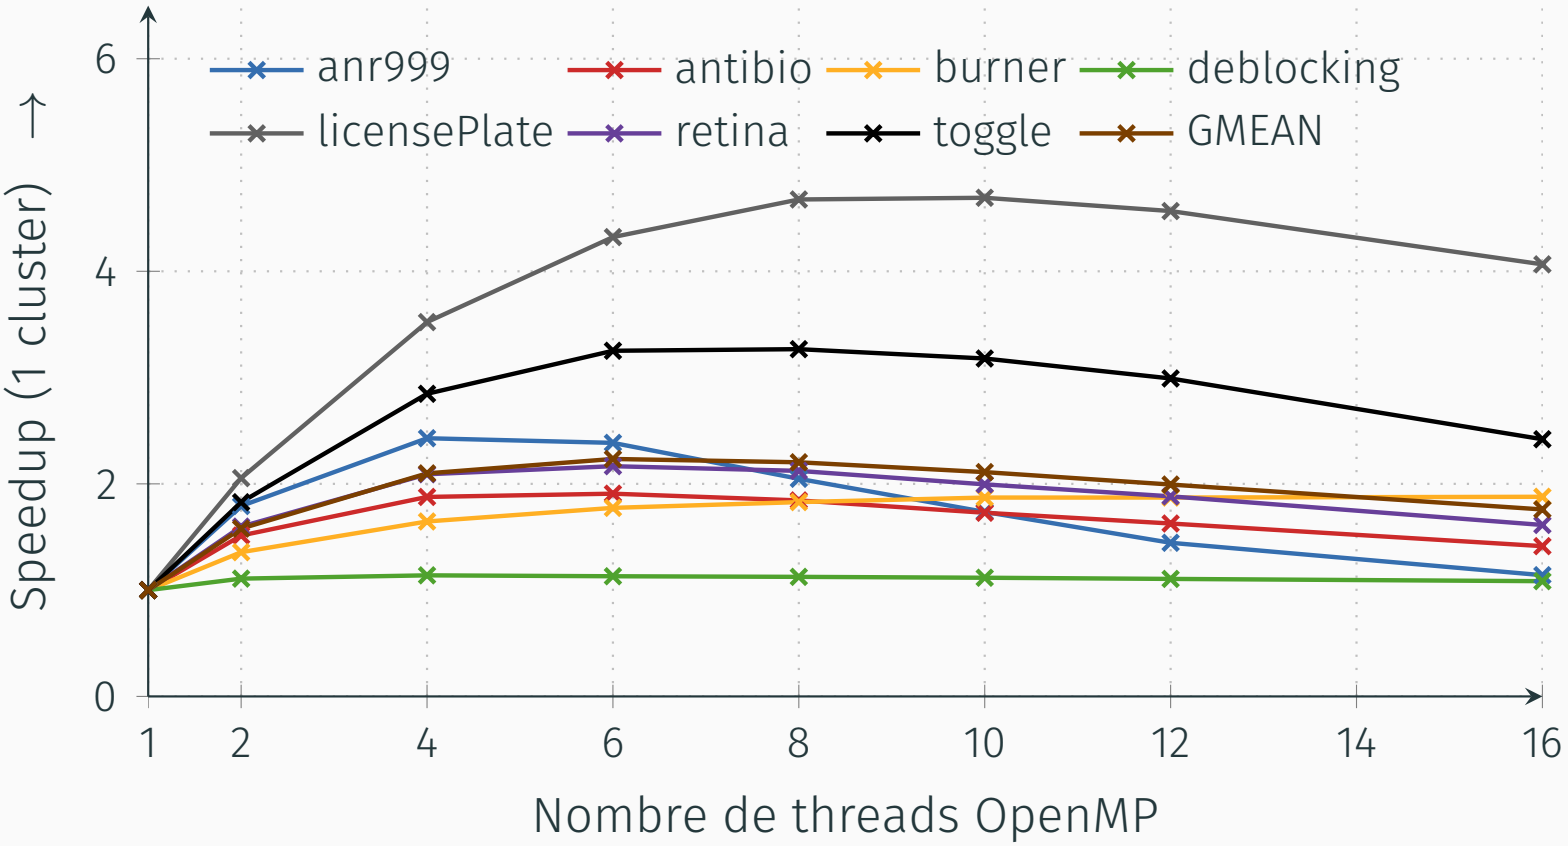

petites images

Bibliothèque OpenMP sur MPPA

SMIL $\longrightarrow$ MPPA

- portage direct et rapide
- 1 cluster de calcul / 16
- environnements d'exécution
- passage à l'échelle
- limitations mémoire

compilation croisée

modèle mémoire

transferts de données

imagettes

$\longrightarrow$ mixer avec des communications inter-clusters

$\longrightarrow$ réduire l'empreinte mémoire

II — Le modèle flot de données

Le flot de données

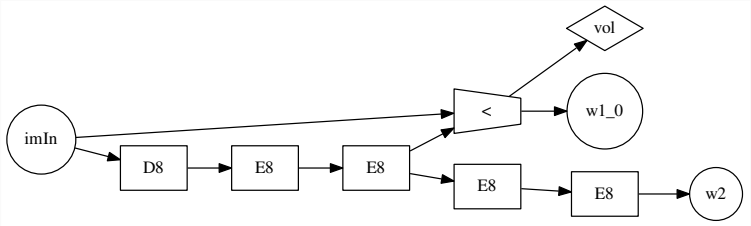

Le modèle et les langages

- graphe producteurs/consommateurs
- années 1970 — KPN
- adapté aux exigences industrielles — Lustre/SCADE
- adapté aux architectures parallèles — StreamIt

Sigma-C, un langage flot de données

- développé pour le MPPA — Andey, ~~Bostan~~
- CEA List

Agents Sigma-C

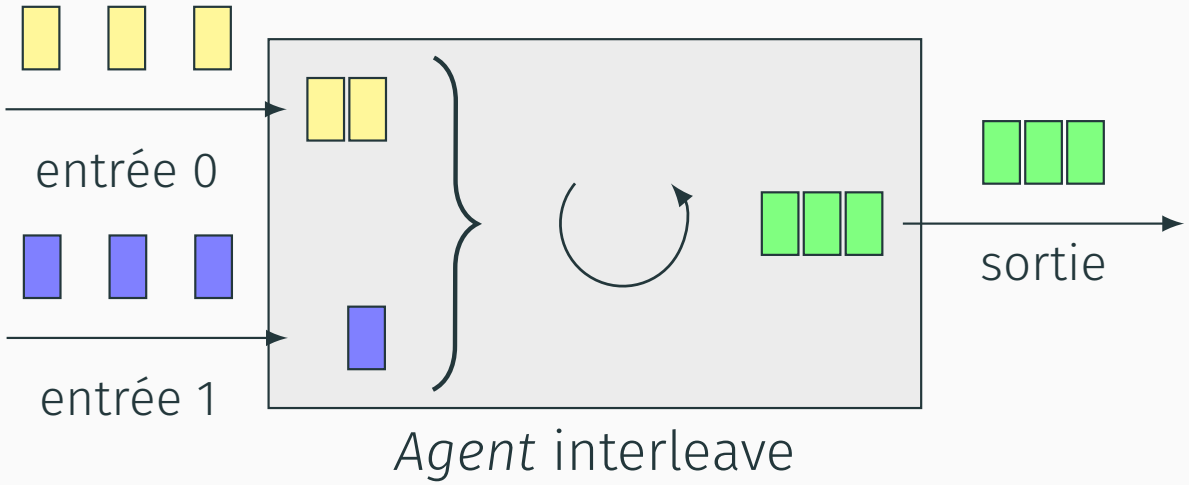


```
agent interleave() {
  interface {
    in<int> in0, in1;
    out<int> out0;
    spec{ in0[2], in1, out0[3] };
  }
  void start() exchange(in0 i0[2], in1 i1, out0 o[3]) {
    o[0] = i0[0], o[1] = i1, o[2] = i0[1];
  }
}
```

Subgraphs Sigma-C

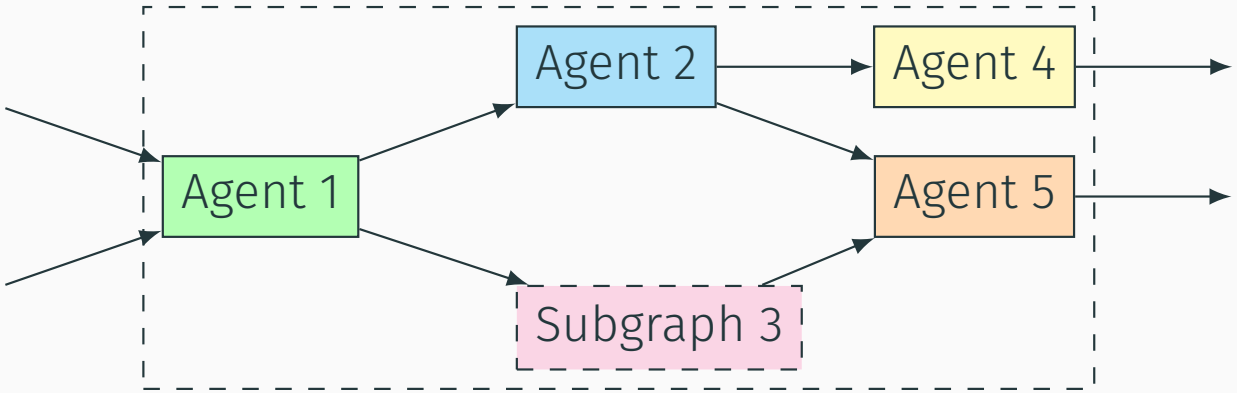

Subgraph bar

```
subgraph bar() {
  interface {
    in<int> in0[2]; out<int> out0, out1;
    spec { { in0[][3]; out0 }; { out1[2] } };
  }
  map {
    agent a1 = new Agent1();
    agent a3 = new Subgraph3();
    connect(in0[0], a1.input0);
    connect(a5.output, out1);
    connect(a1.output0, a2.input);
    connect(a3.output, a5.input1);
  }
}
```

Conversion de FREIA en Sigma-C

À partir de code FREIA séquentiel

```
freia_aipo_threshold(im1, im0, 50, 150, true); // arithmétique
freia_aipo_erode_8c(im2, im1, kernel);         // morphologique
freia_aipo_dilate_8c(im3, im2, kernel);        // morphologique
```

Générer automatiquement des subgraphs Sigma-C

```
subgraph foo() {
  int16_t kernel[9] = {0,1,0, 0,1,0, 0,1,0};
  ...
  agent thr = new img_threshold_img();
  agent ero = new img_erode(kernel);
  agent dil = new img_dilate(kernel);
  ...
  connect(thr.output, ero.input);
  connect(ero.output, dil.input);
  ...
}
```

Contraintes sur les applications Sigma-C

Agents

- 1 agent $\rightarrow$ 1 cœur de calcul — *utilisation partielle*
- 2 Mo pour 16 cœurs — *mem(1 agent)* $\leq$ *128 ko*
- coût d'itération fixe — *grouper les pixels par lignes*

Graphes

- débit : nœud le plus lent — *équilibrage fusion/fission*
- placement : communications inter-clusters — *peu de clusters*
- temps d'activation constant — *gros graphes*

Fusion des opérateurs arithmétiques

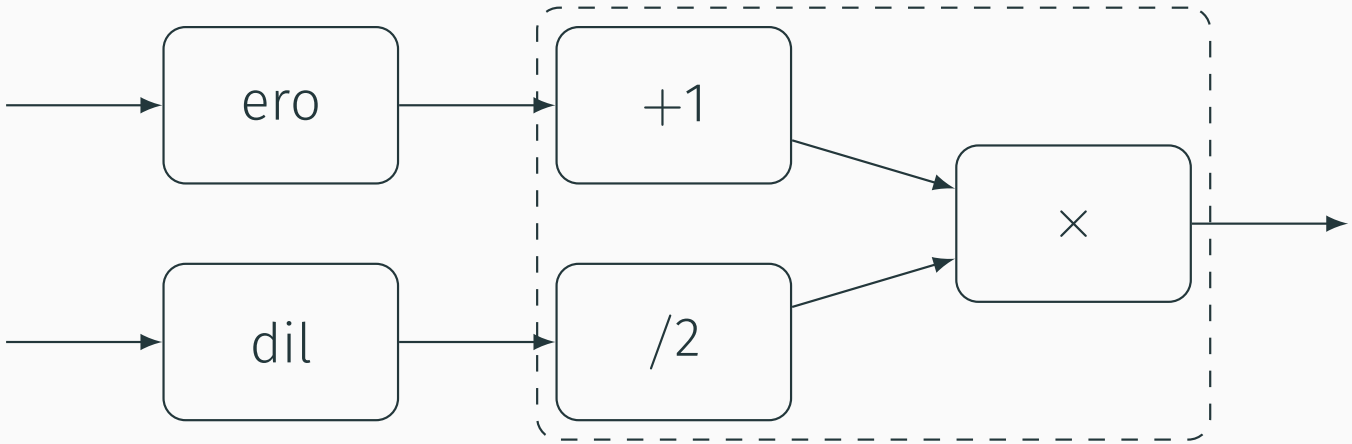

Fusion des opérateurs arithmétiques

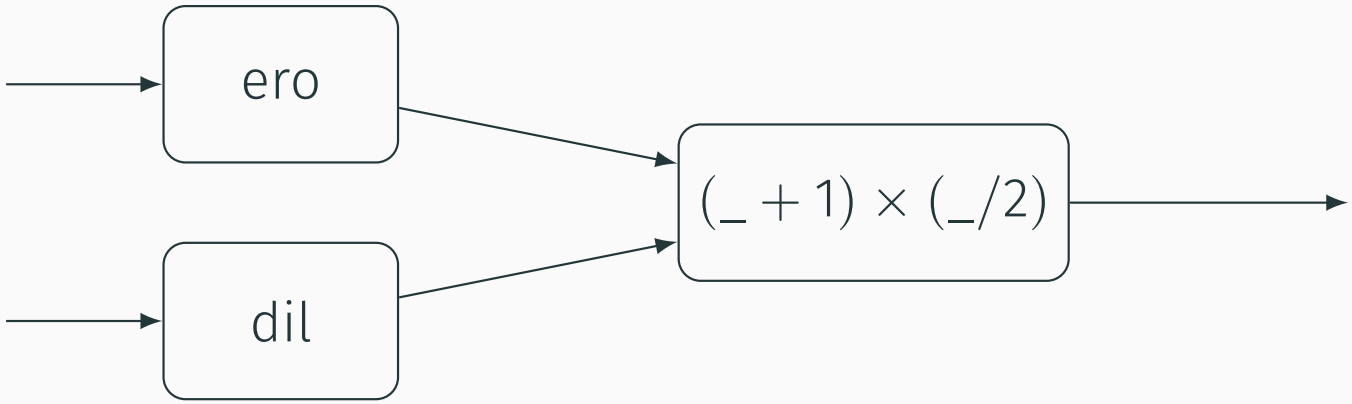

Optimisation : réduction des communications

```
void freia_cipo_geodesic_reconstruct(freia_data2d *immarker,
                                     freia_data2d *immask) {
  int32_t volcurrent, volprevious;
  freia_global_vol(immarker, &volcurrent);
  do {
    volprevious = volcurrent;
    freia_dilate(immarker, immarker);
    freia_inf(immarker, immarker, immask);
    freia_global_vol(immarker, &volcurrent);
  } while (volcurrent != volprevious);
}
```

- pas de boucle dynamique en Sigma-C $\longrightarrow$ **`while`** sur hôte
- reconstruction géodésique : suite stationnaire d'itérations

$\Longrightarrow$ déroulement partiel

Chaîne de compilation FREIA → Sigma-C

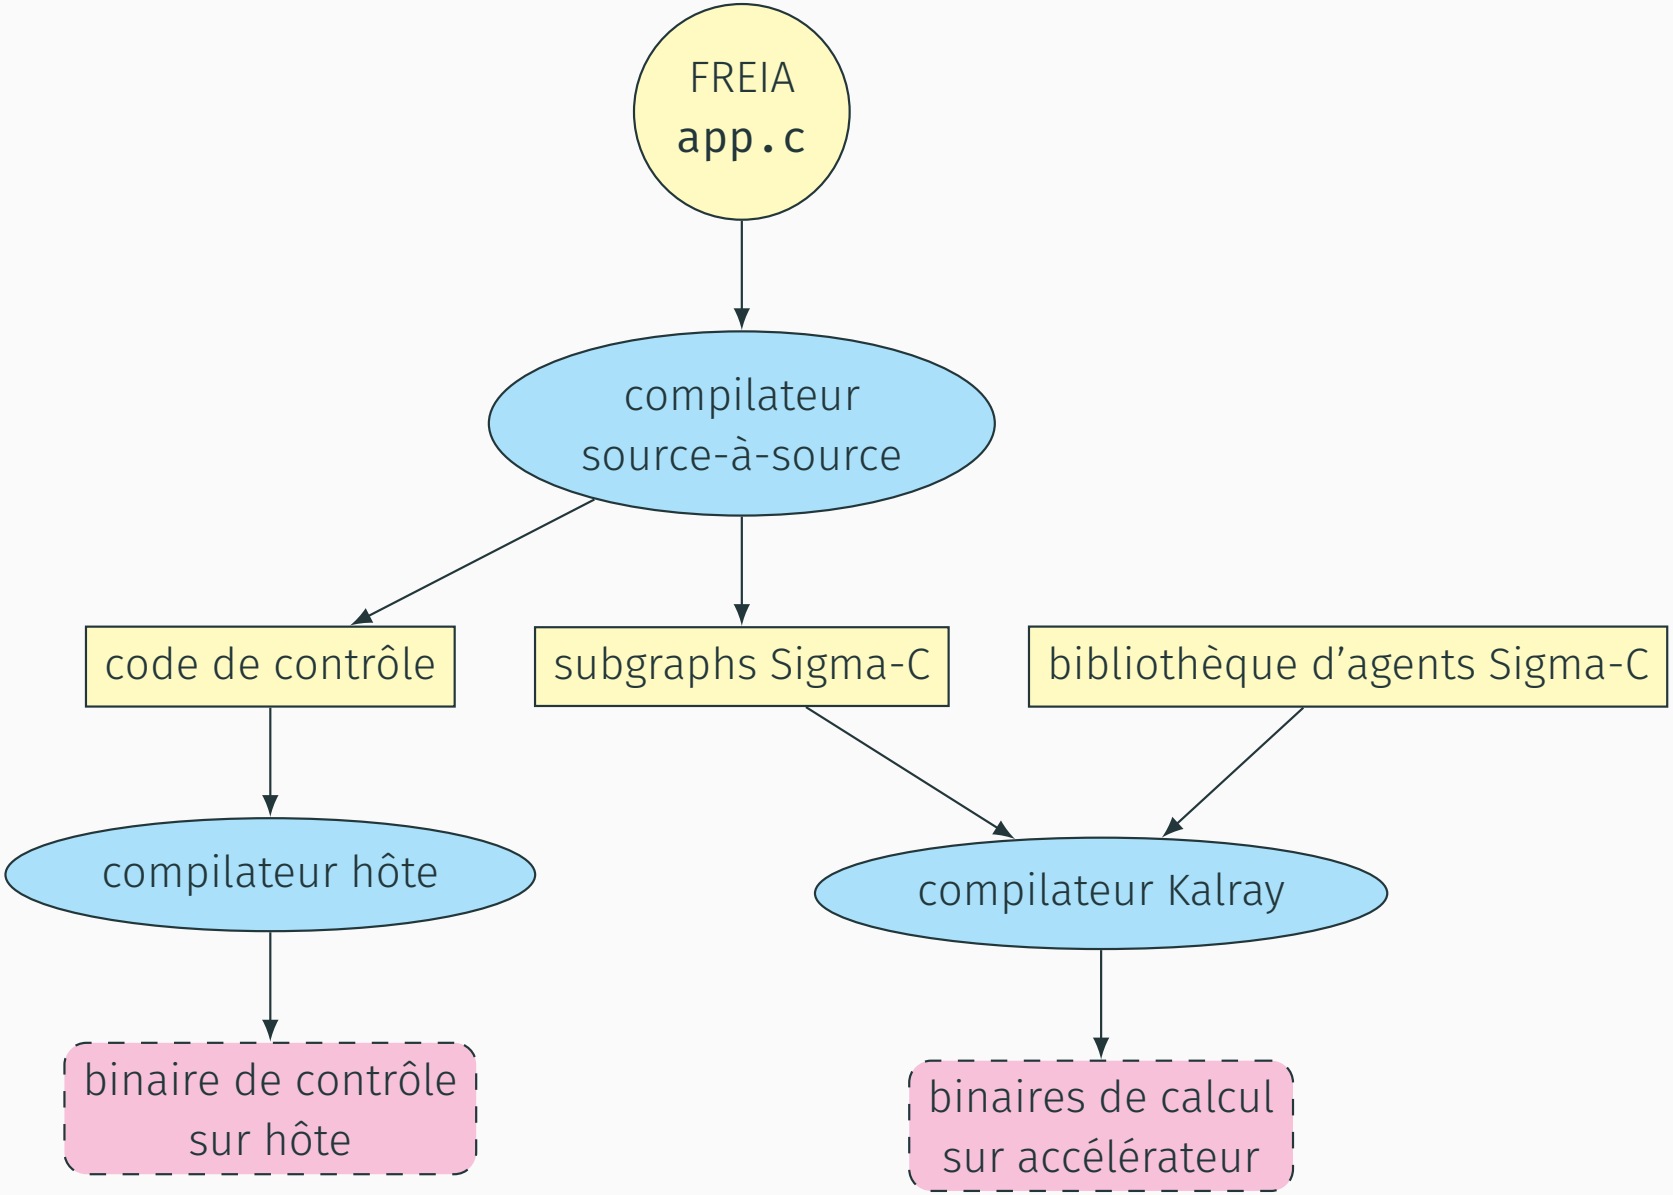

Environnement d'exécution Sigma-C

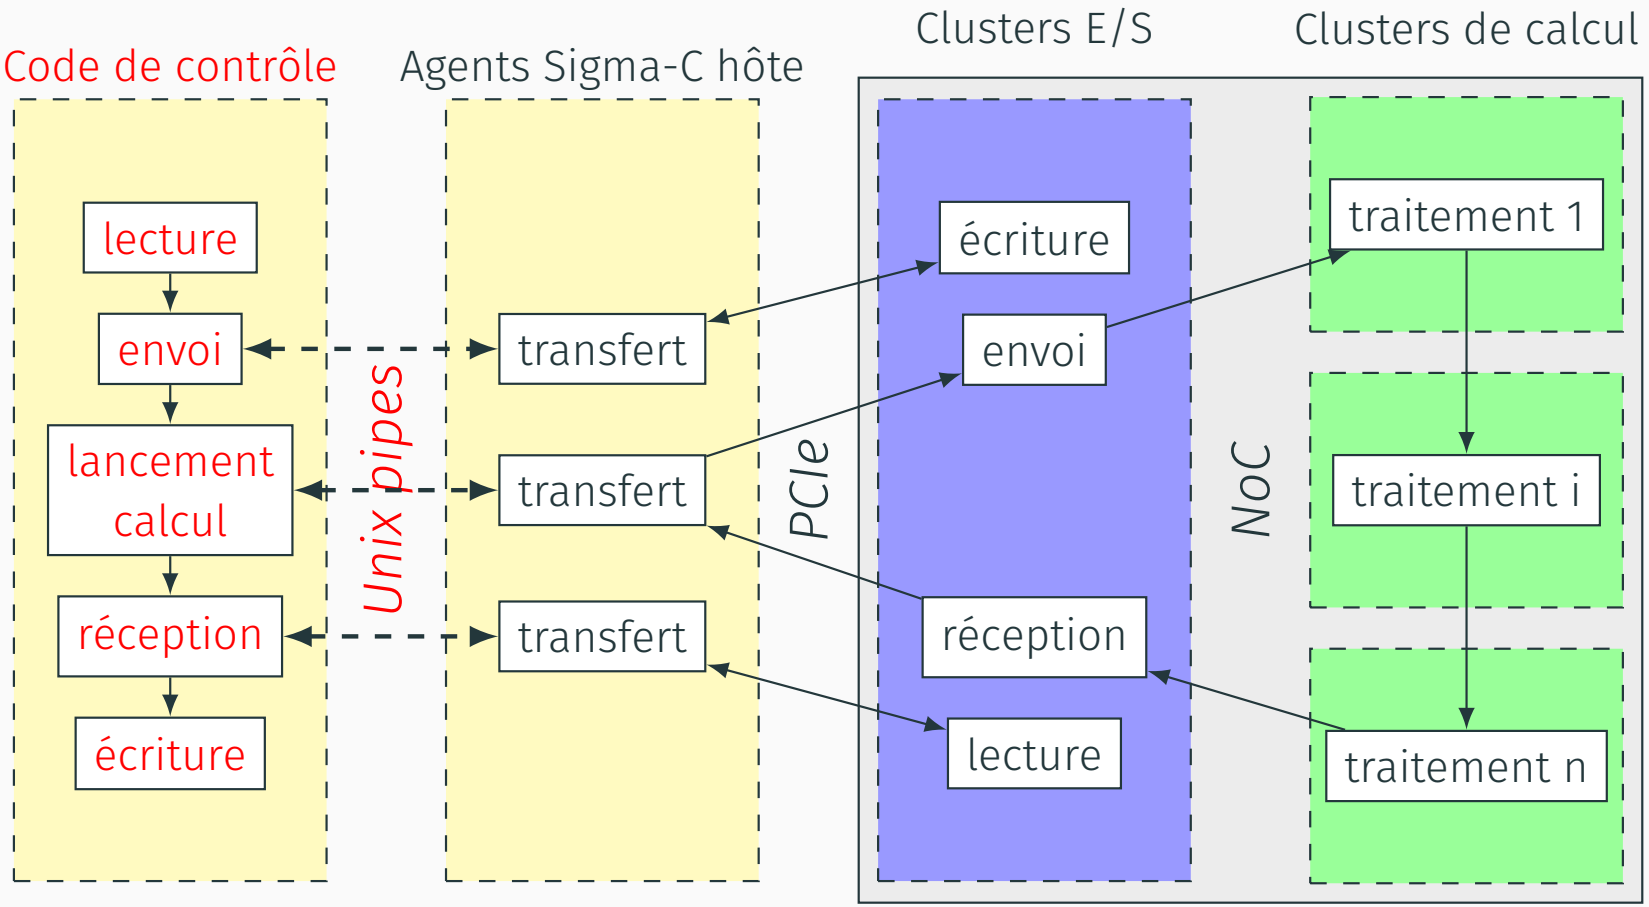

Évaluation : Sigma-C sur multicœur et MPPA

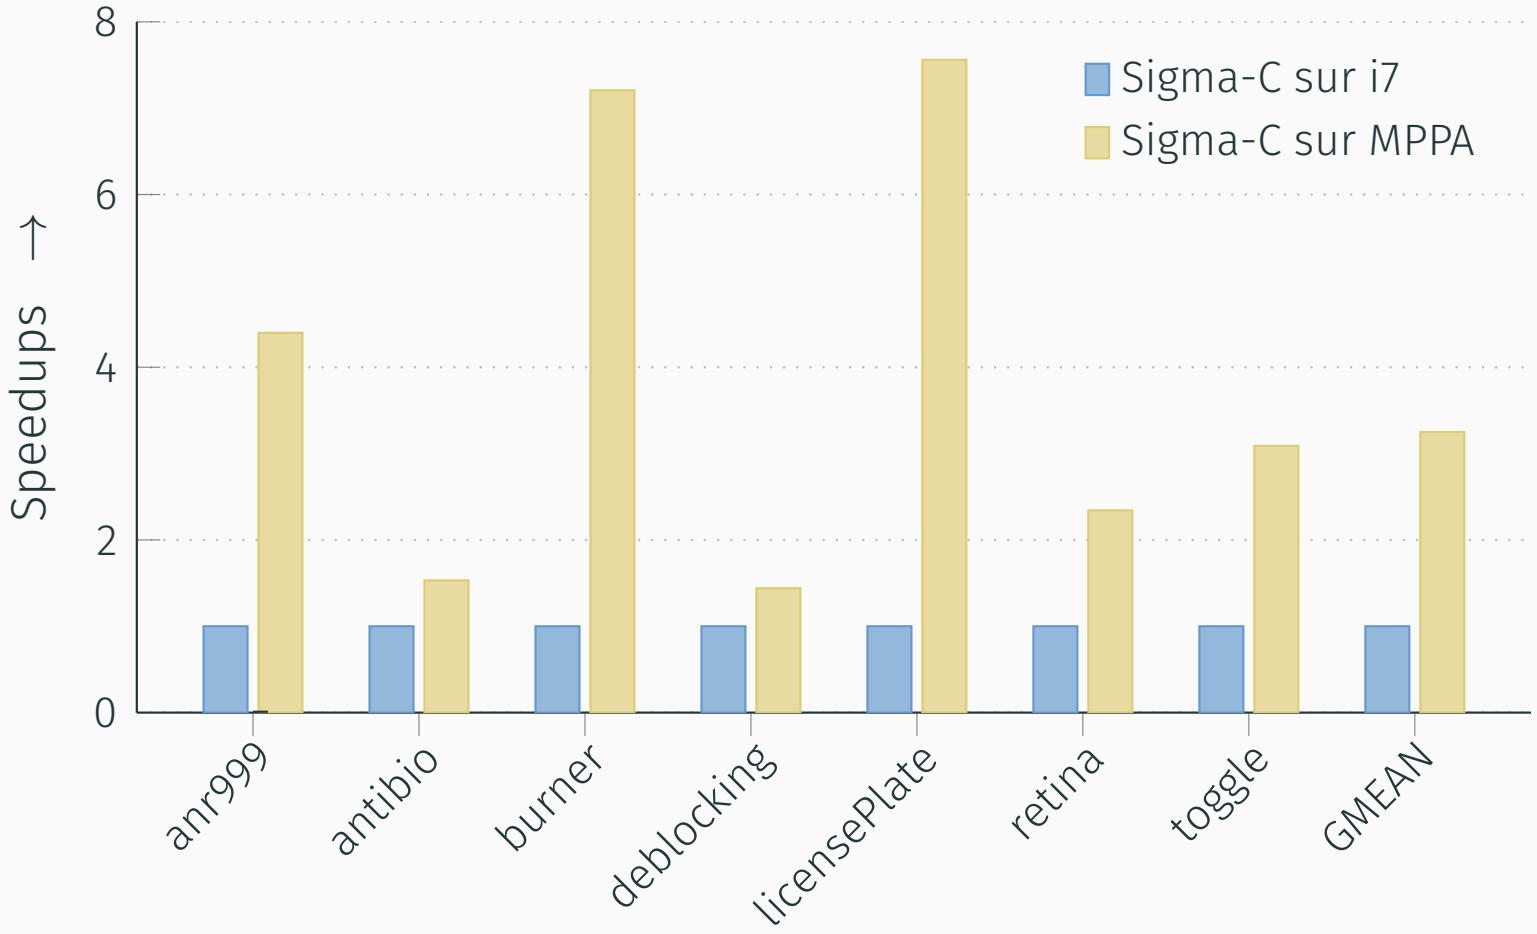

Flot de données et processeurs manycore

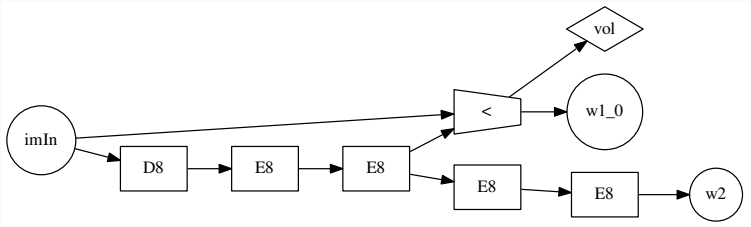

FREIA → Sigma-C → MPPA

- bibliothèque d'opérateurs
- compilation source-à-source FREIA → Sigma-C
- environnement d'exécution pour E/S
- optimisations pour le processeur MPPA

Résultats

- modèle strict
- compilation automatique
- bonnes performances sur MPPA
- *publication LCPC 2014*

morceaux d'applications

3P

malgré usage partiel

III — Le modèle OpenCL

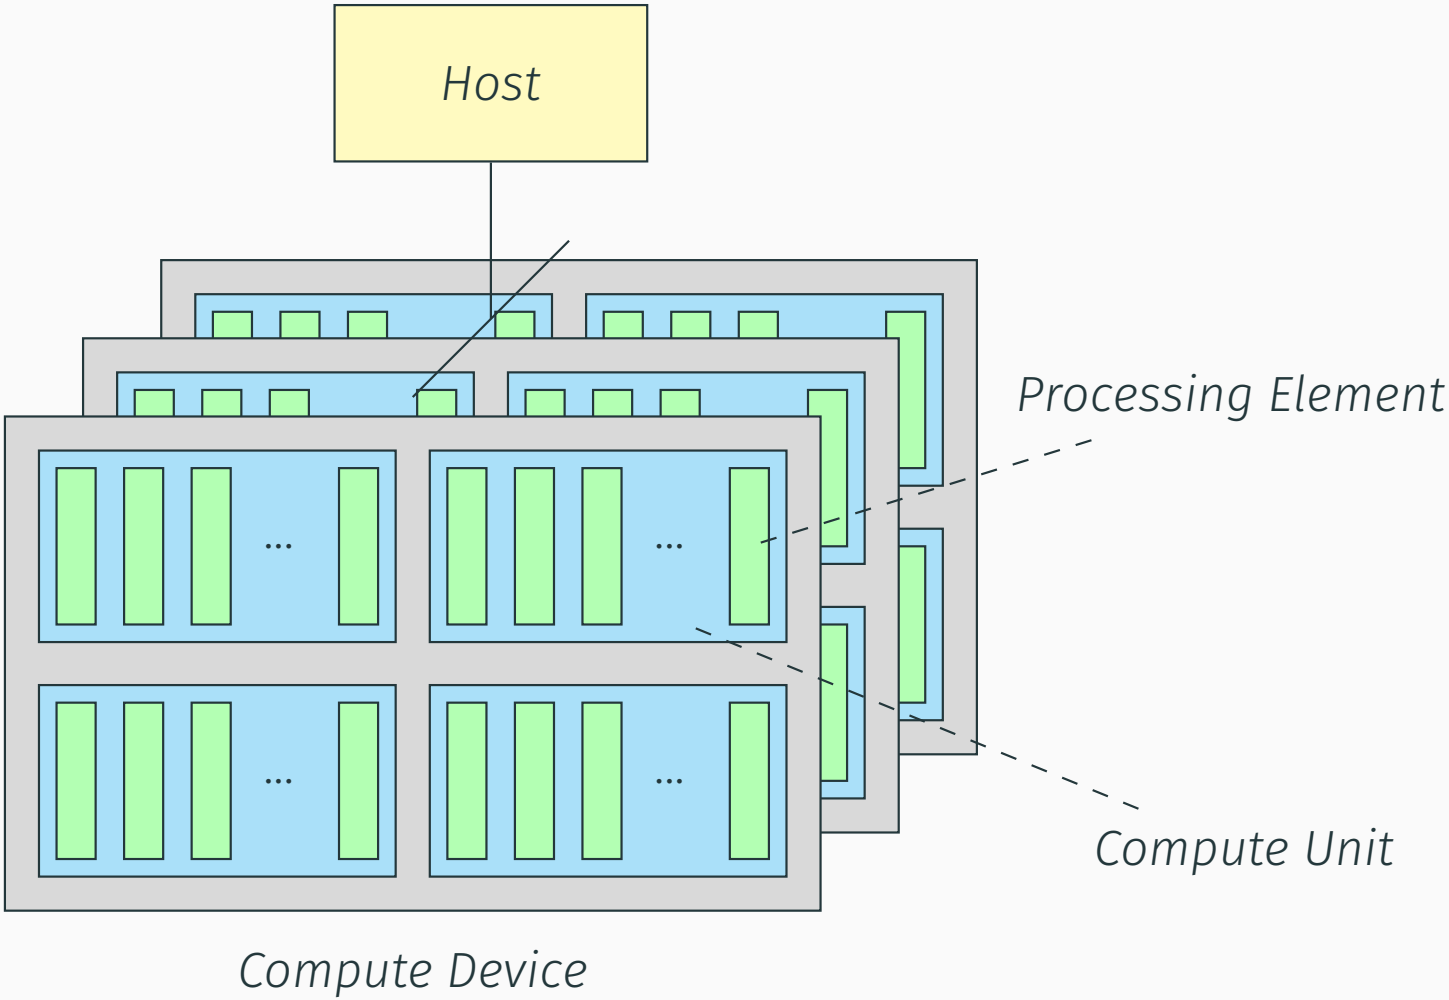
Host
Processing Element
Compute Unit
Compute Device

Addition de vecteurs en OpenCL : noyau de calcul

```
__kernel void vecAdd(__global float *a,
                     __global float *b,
                     __global float *c,
                     const unsigned int n) {

  unsigned int id = get_global_id(0);

  if (id < n)
    c[id] = b[id] + a[id];
}
```

Addition de vecteurs en OpenCL : code hôte

```
// Initializations
clGetPlatformIDs(1, &cpPlatform, NULL);
clGetDeviceIDs(cpPlatform, CL_DEVICE_TYPE_GPU, 1, &device_id, NULL);
ctx = clCreateContext(0, 1, &device_id, NULL, NULL, &err);
q = clCreateCommandQueue(ctx, device_id, 0, &err);

// Create the compute program from the source buffer
prgm = clCreateProgramWithSource(ctx, 1, (const char **)&kernelSource, NULL, &err);
clBuildProgram(prgm, 0, NULL, NULL, NULL, NULL);

// Create the compute kernel in the program we wish to run
knl = clCreateKernel(prgm, "vecAdd", &err);

// Create the input and output arrays in device memory
d_a = clCreateBuffer(ctx, CL_MEM_READ_ONLY, bytes, NULL, NULL);
d_b = clCreateBuffer(ctx, CL_MEM_READ_ONLY, bytes, NULL, NULL);
d_c = clCreateBuffer(ctx, CL_MEM_WRITE_ONLY, bytes, NULL, NULL);

// Write our data set into the input array in device memory
err = clEnqueueWriteBuffer(q, d_a, CL_TRUE, 0, bytes, h_a, 0, NULL, NULL);
err |= clEnqueueWriteBuffer(q, d_b, CL_TRUE, 0, bytes, h_b, 0, NULL, NULL);

// Set the arguments to our compute kernel
err |= clSetKernelArg(knl, 0, sizeof(cl_mem), &d_a);
err |= clSetKernelArg(knl, 1, sizeof(cl_mem), &d_b);
err |= clSetKernelArg(knl, 2, sizeof(cl_mem), &d_c);
err |= clSetKernelArg(knl, 3, sizeof(unsigned int), &n);

// Execute the kernel over the entire range of the data set
err = clEnqueueNDRangeKernel(q, knl, 1, NULL, &globalSize, &localSize, 0, NULL, NULL);
clFinish(q);

// Read the results from the device
clEnqueueReadBuffer(q, d_c, CL_TRUE, 0, bytes, h_c, 0, NULL, NULL);
```

Chaîne de compilation FREIA → OpenCL

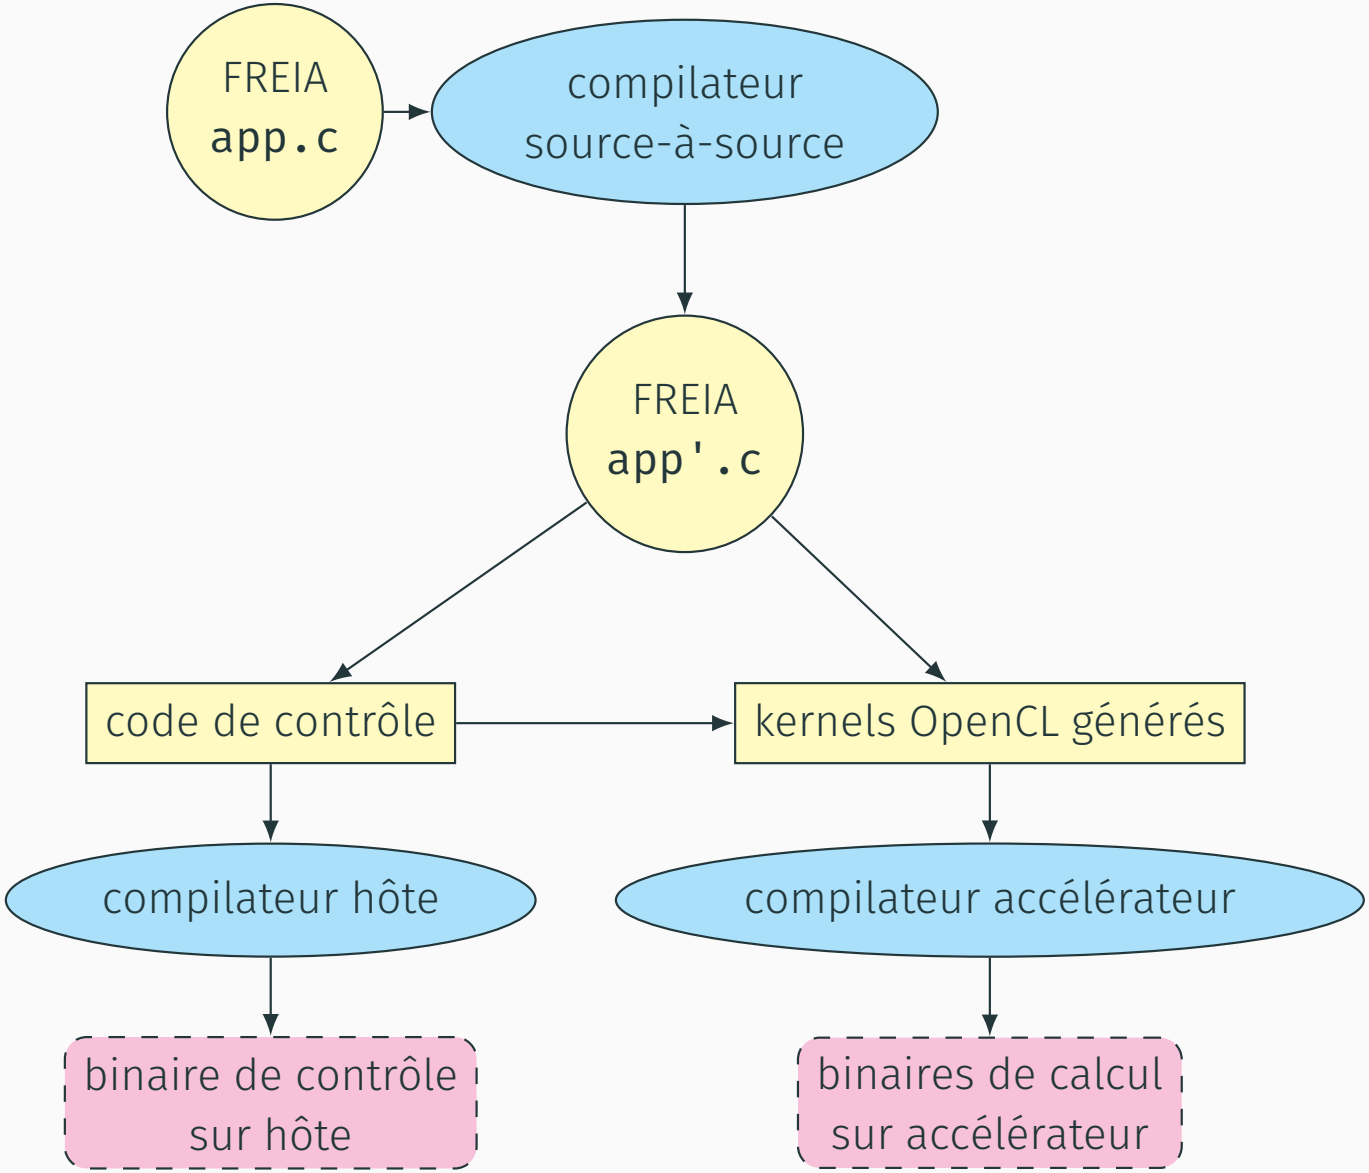

OpenCL sur le MPPA, multicœur et GPU : temps d'exécution

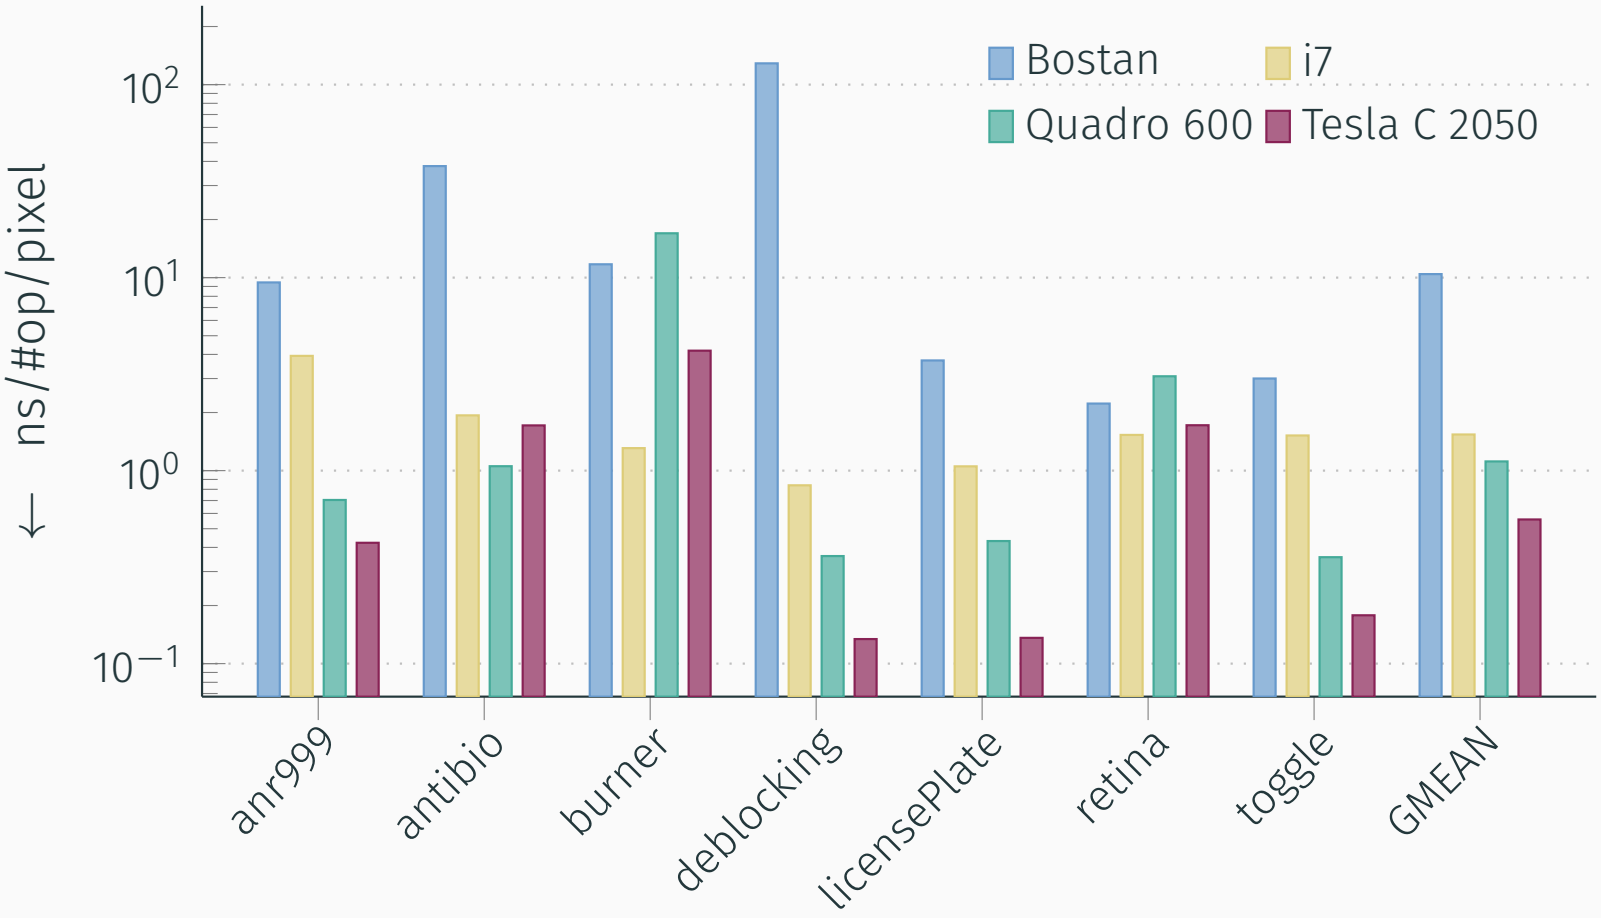

OpenCL sur le MPPA, multicœur et GPU : énergie

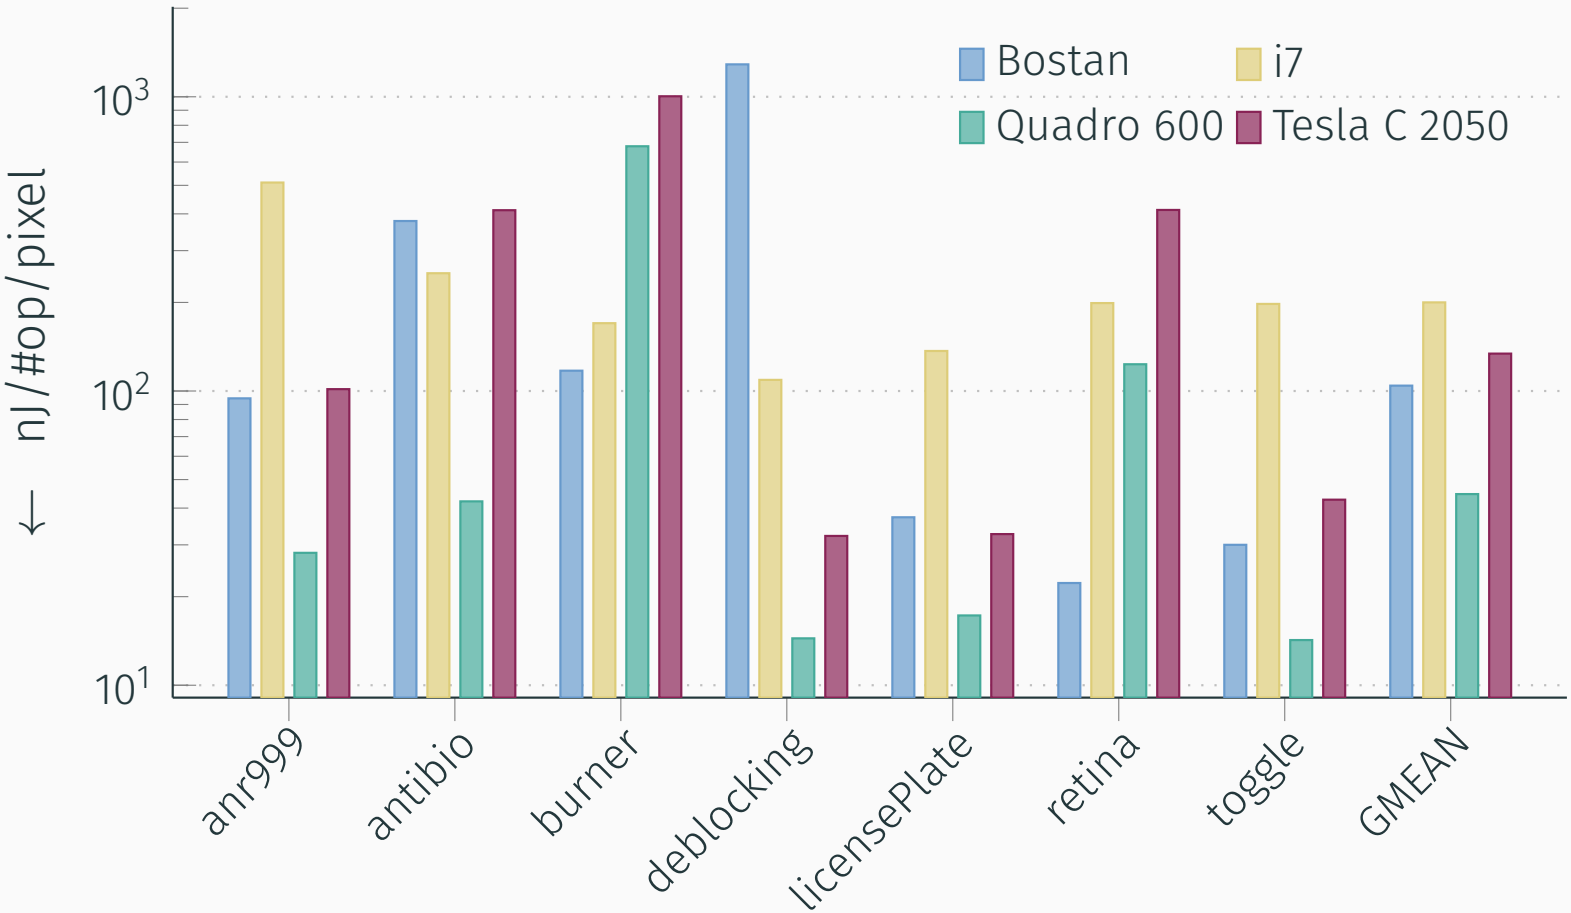

Le modèle OpenCL

OpenCL $\longrightarrow$ MPPA

- modèle répandu
- E/S gérées par le modèle
- support partiel d'OpenCL
- performances à améliorer

évolutions de la pile logicielle

accès à la mémoire globale ?

$\longrightarrow$ à éviter actuellement sur MPPA pour ce type d'applications

Quel modèle choisir ?

Andey vs. Bostan : OpenMP sur 1 cluster

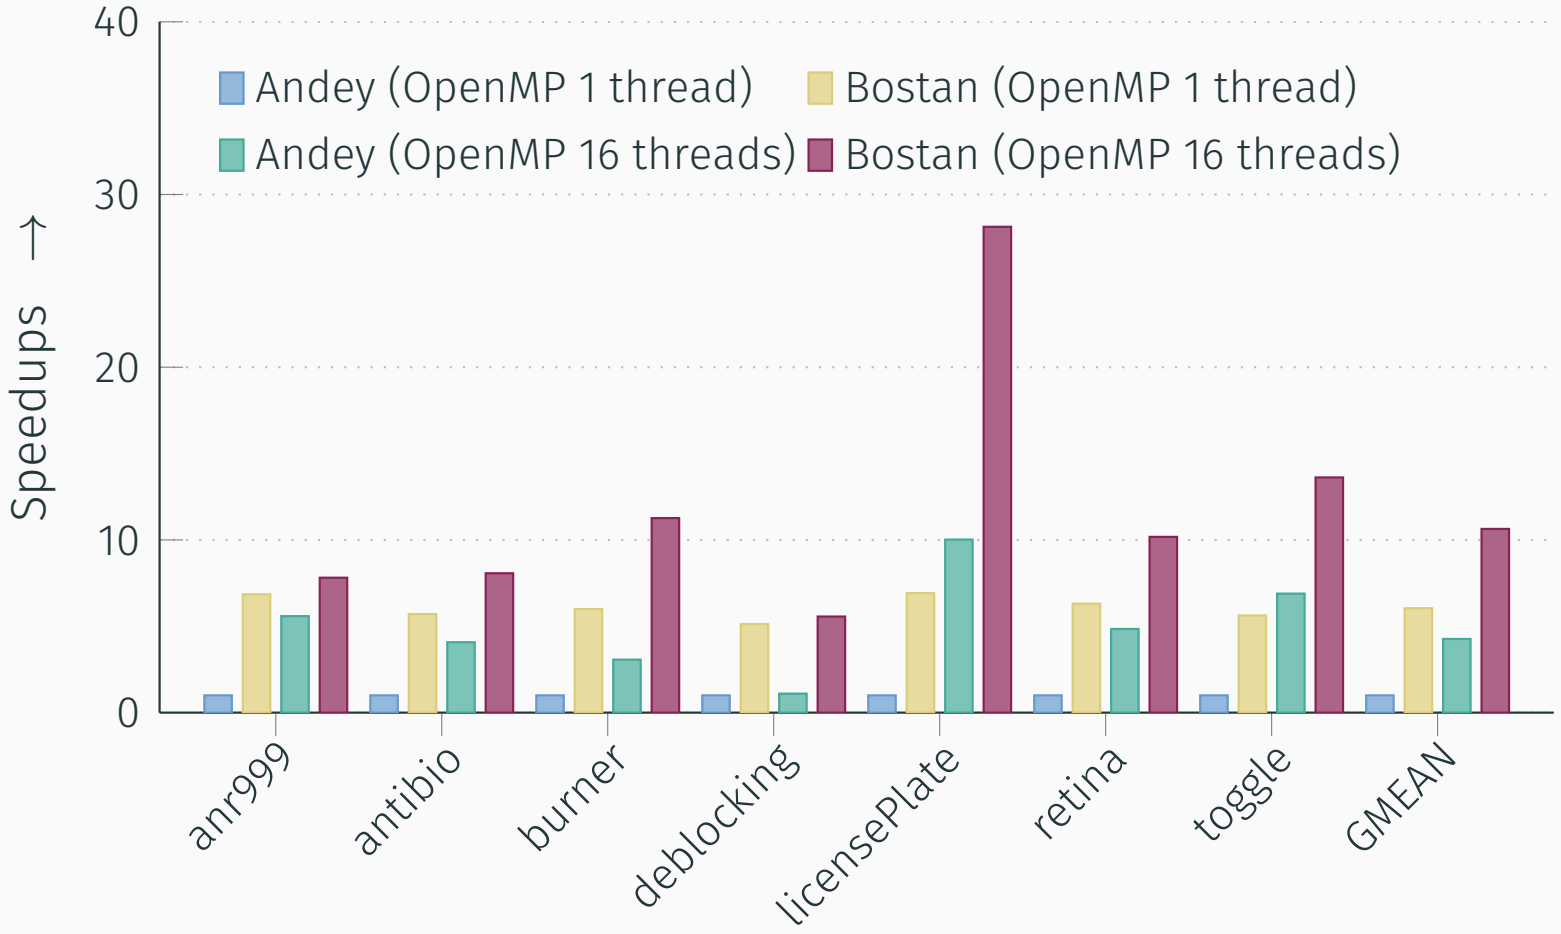

OpenCL sur MPPA : Andey vs. Bostan

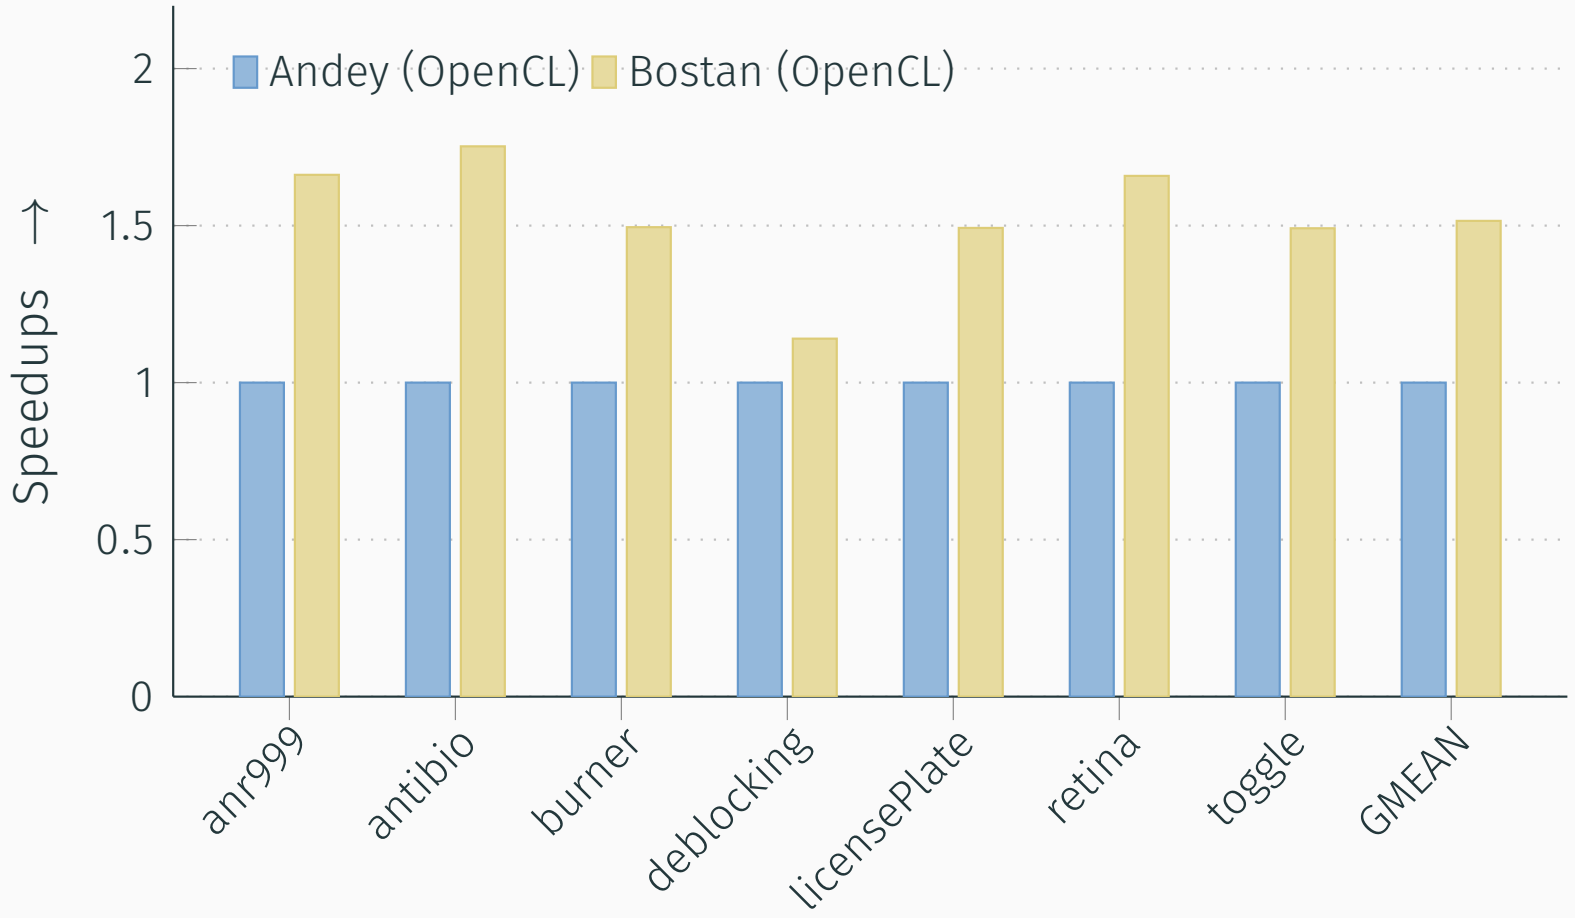

Le meilleur modèle de programmation sur MPPA ?

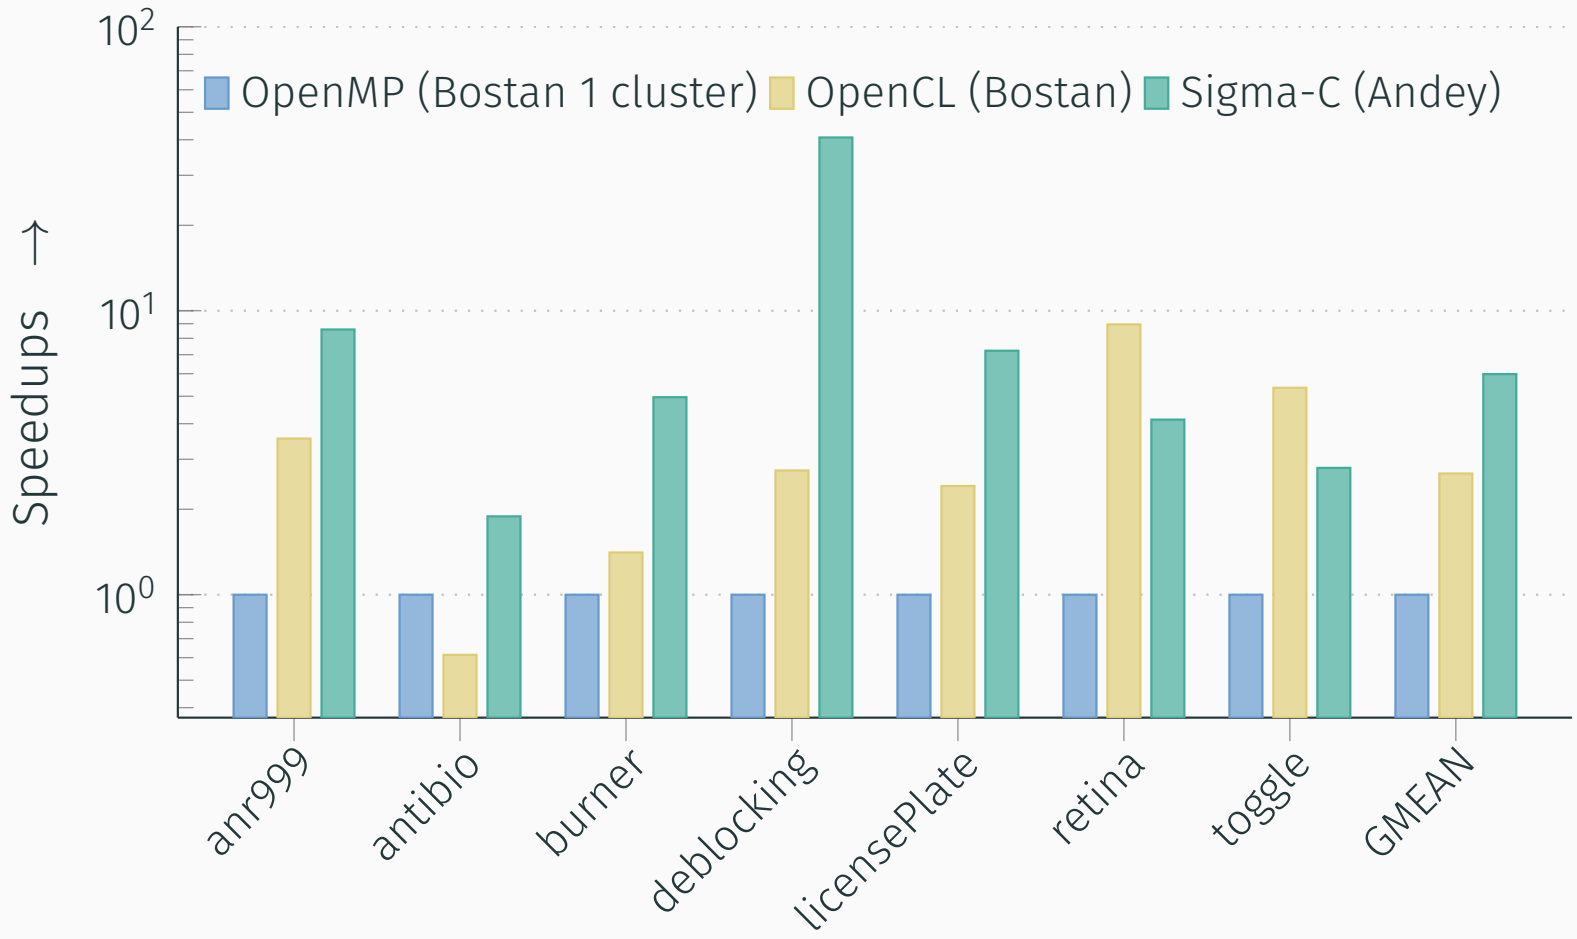

Comparaison des modèles

Modèle	Avantages	Inconvénients
OpenMP	• répandu • portage rapide	• 16 cœurs sur 256 • mémoire : 2 Mo (code, données) • transferts depuis l'hôte
Sigma-C	• performant • communications	• trop statique • contrôle hôte • nouveau langage • abandonné
OpenCL	• répandu • portage rapide	• implémentation en cours • accès mémoire • performances ?
OpenMP + IPC	• 256 cœurs • performances ?	• tuilage • communications

Comparaison avec d'autres accélérateurs

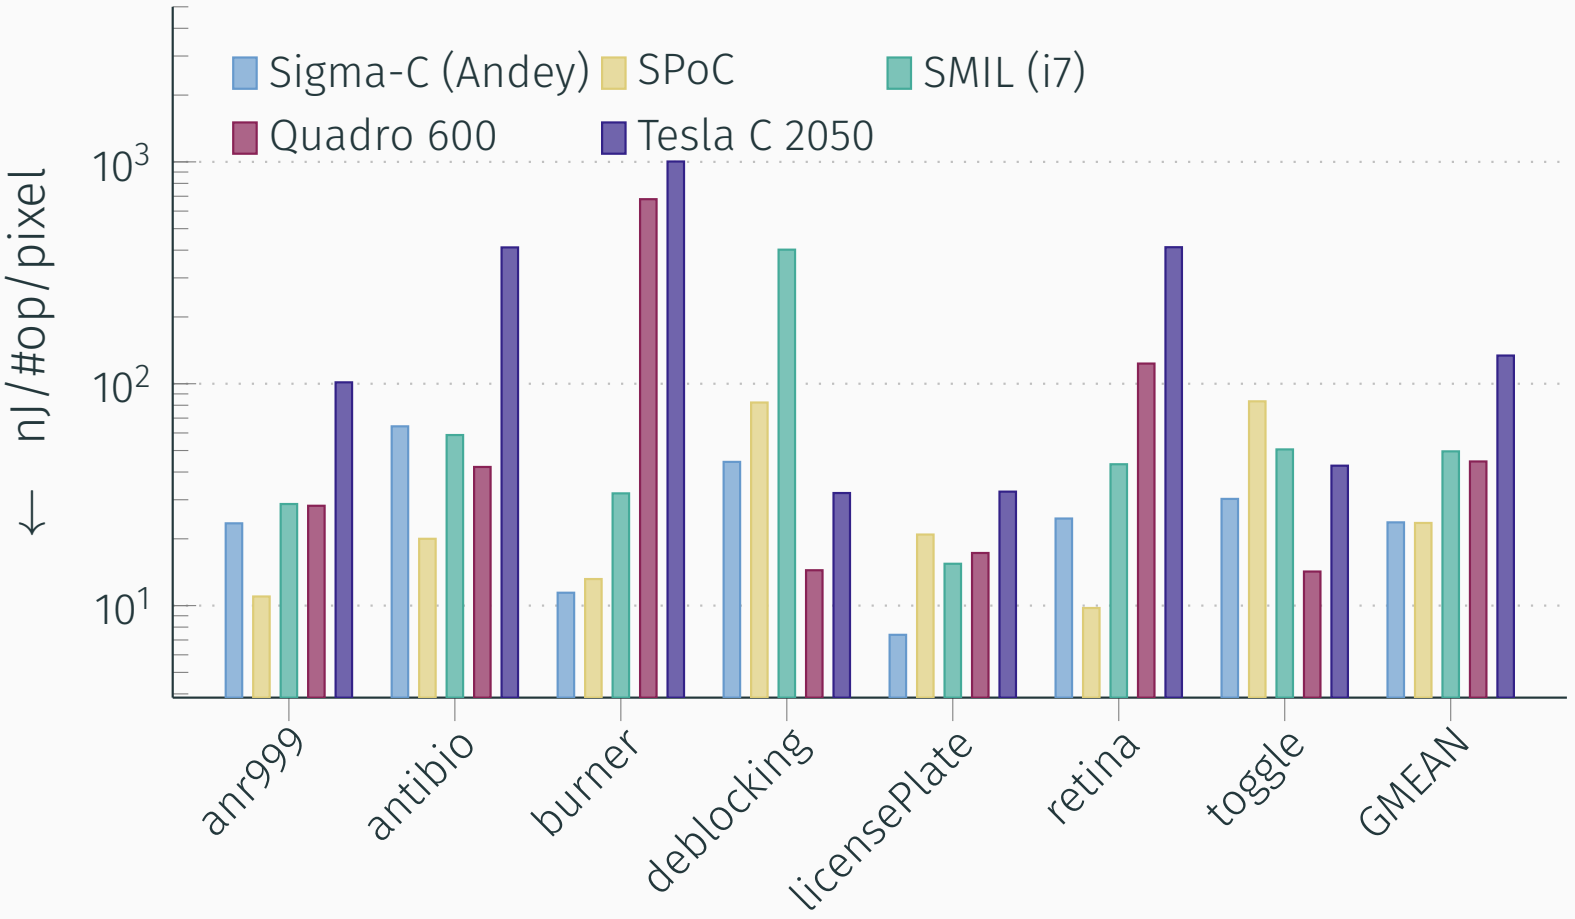

Conclusions & Perspectives

Contributions principales

Comparaisons expérimentales sur MPPA

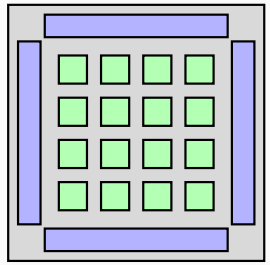

- 3 modèles de programmation parallèle
- 2 générations de processeurs

Preuve de la possibilité d'atteindre les *3P*

- développement d'un environnement logiciel intégré
- regroupant plusieurs chaînes de compilation
- restreint au traitement d'images
- *publication CPC 2016*

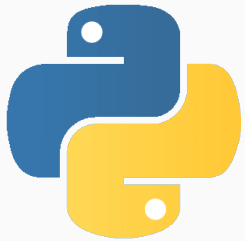

Les piles logicielles SMIL et FREIA

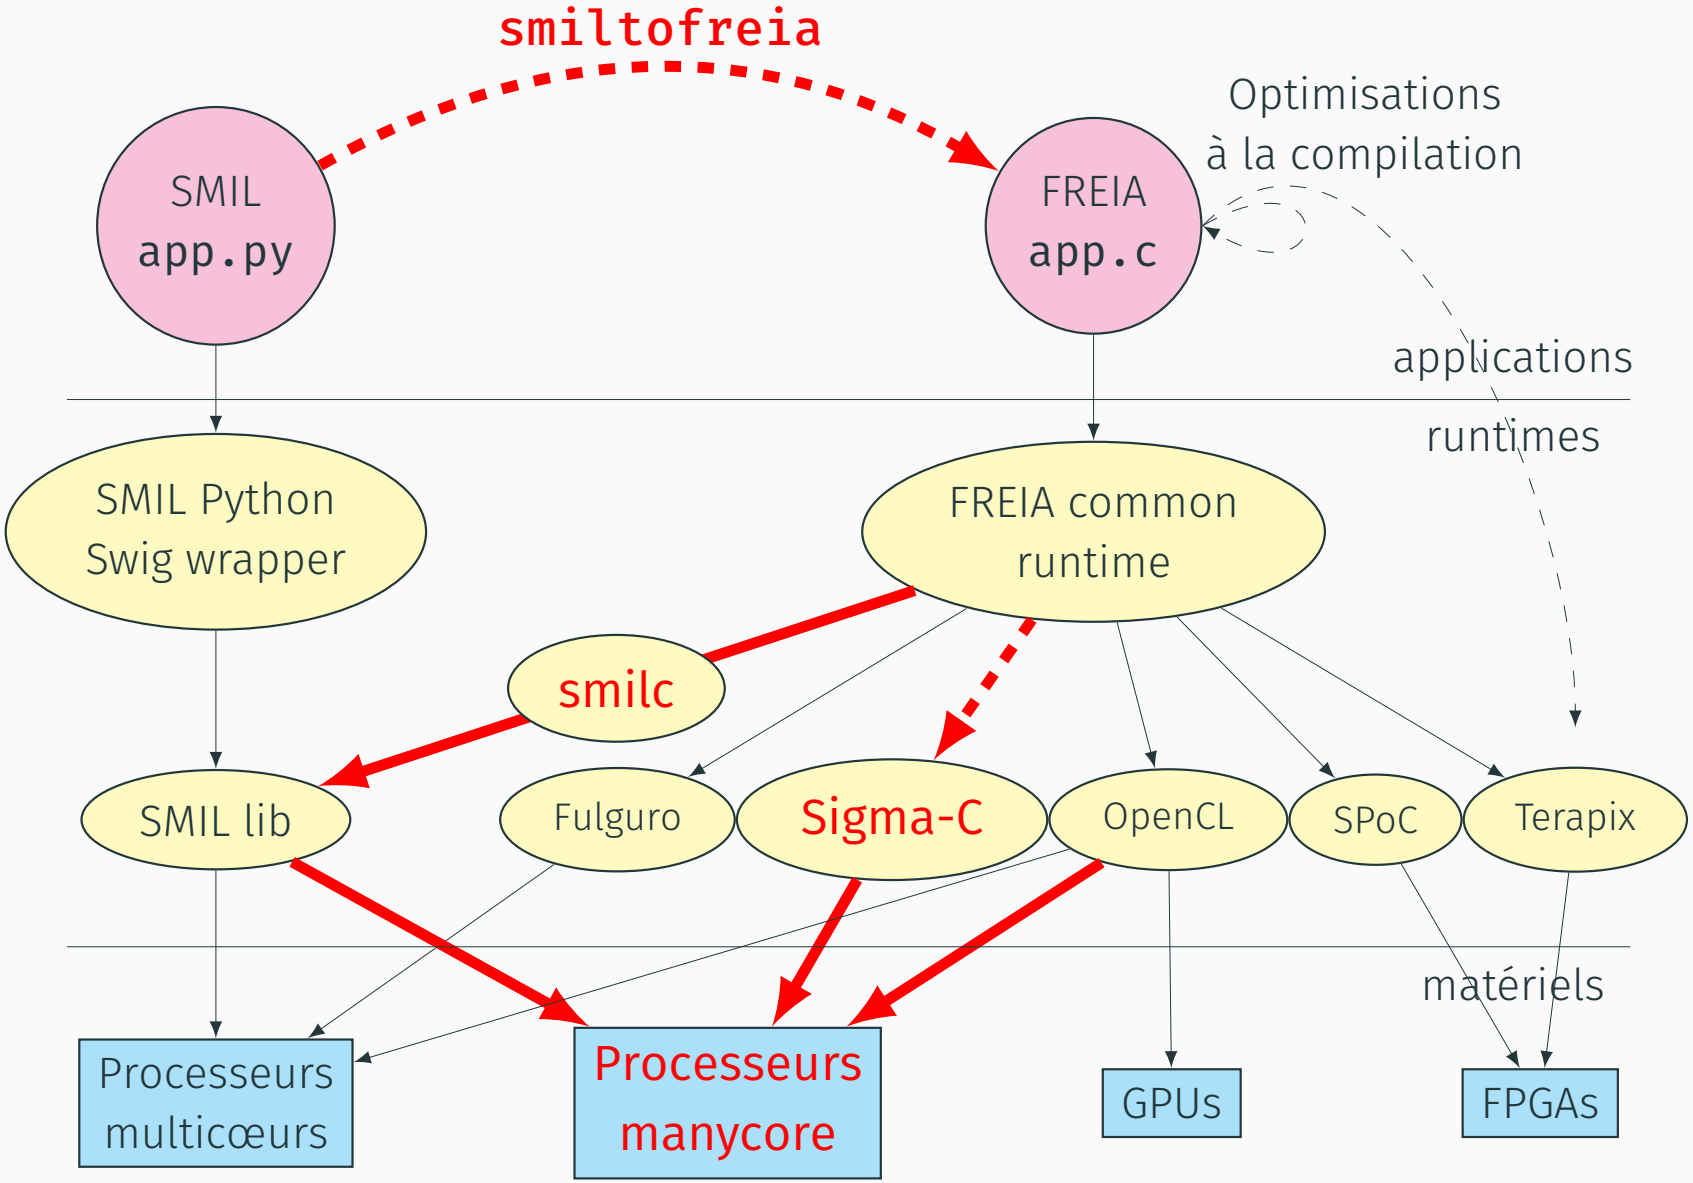

Environnement logiciel : `freiacc` 1 app $\longrightarrow$ *3P*

- ✓ Programmabilité
- ? Performance
- ✓ Portabilité

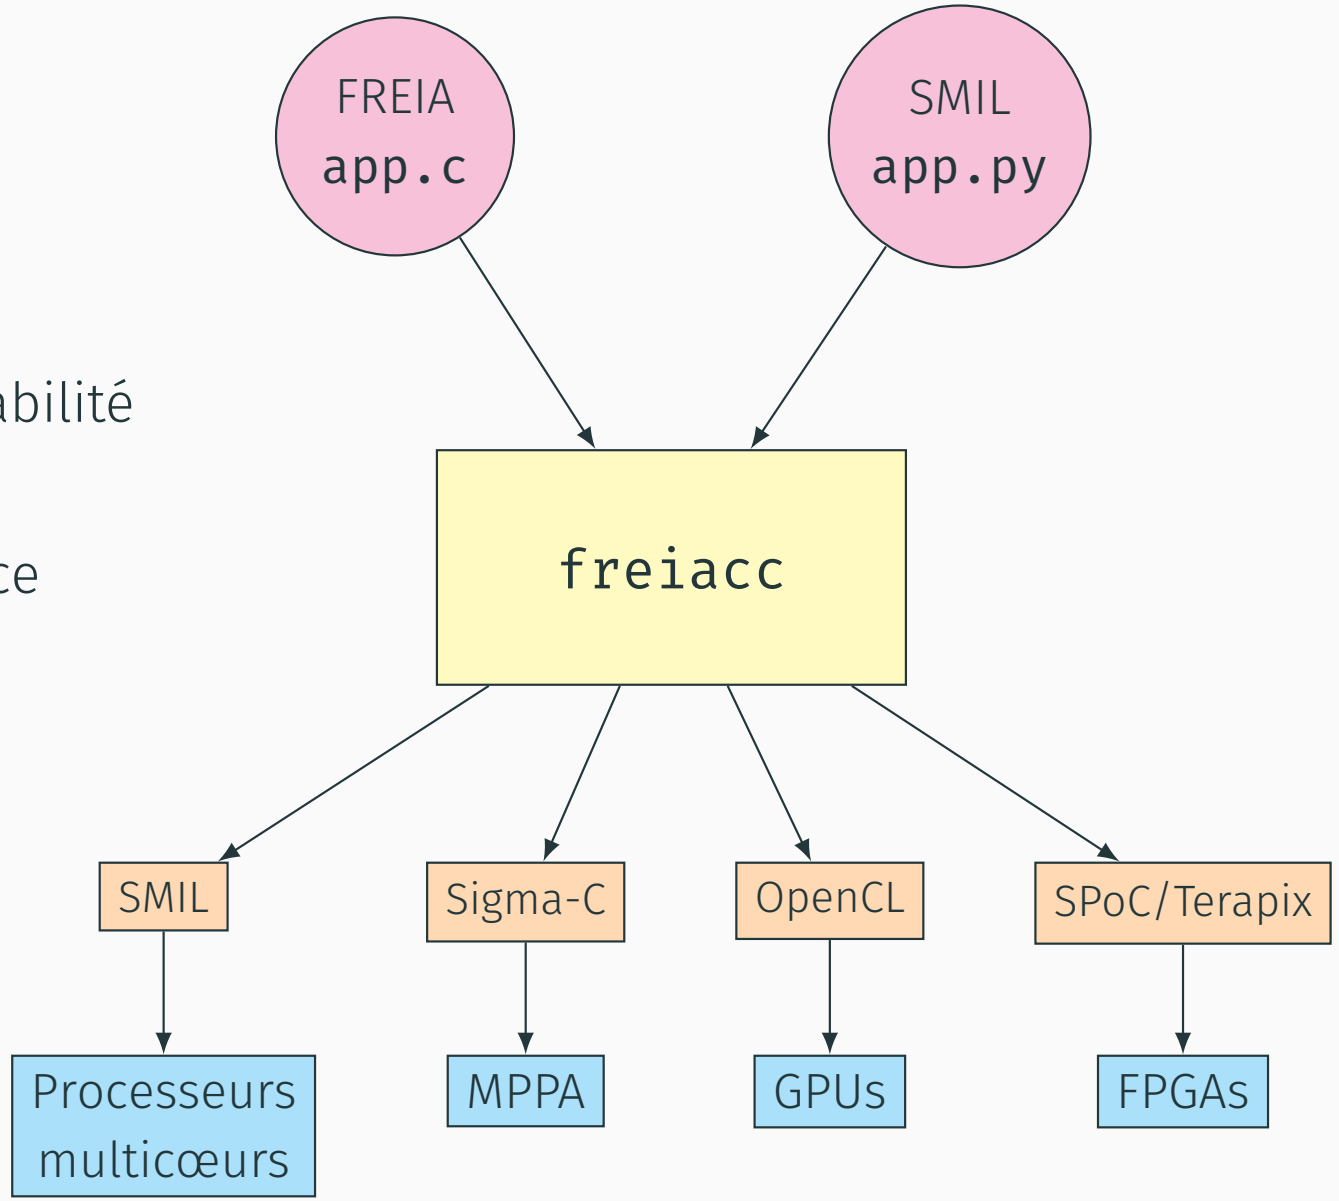

Perspective : autre modèle pour le MPPA

Objectif : utiliser tous les cœurs du MPPA

- OpenMP sur les clusters en C : réécriture des noyaux
- environnement d'exécution : transferts, tuilage, recouvrements
- communications inter-clusters (à la MPI)
- optimisations via PIPS (fusion d'opérateurs, etc.)

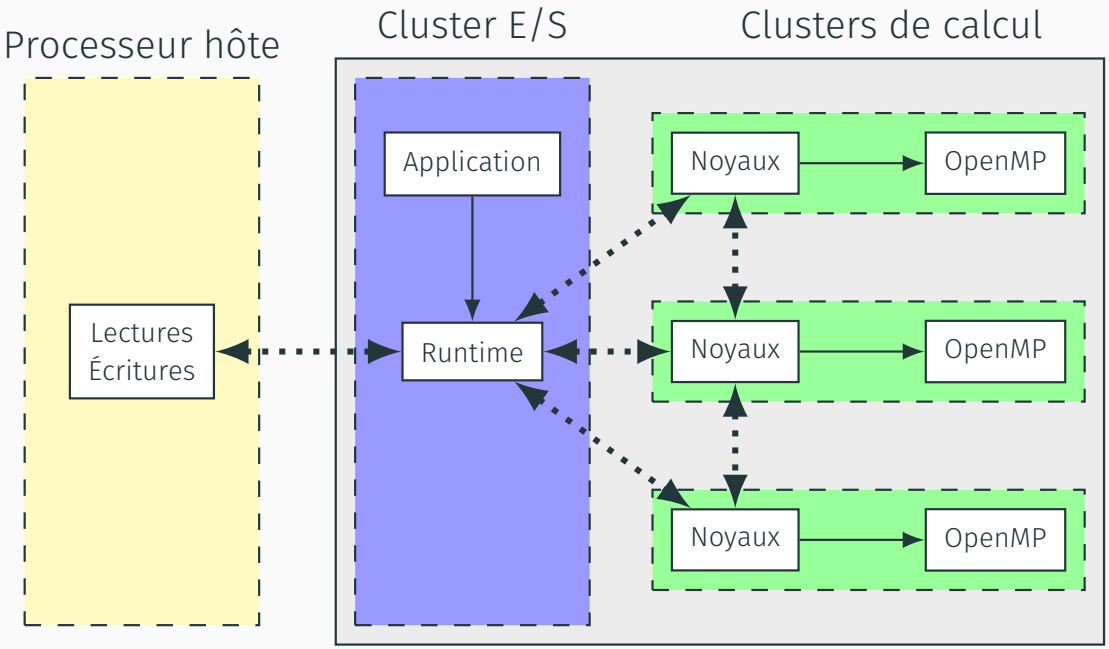

Perspective : DSLs et nouvelles architectures

Le processeur MPPA

- potentiel embarqué vs. complexité architecturale *ok !*
- mémoire : taille SMEM, accès DDR…

Traitement d'image

- portage d'algorithmes non locaux *segmentation*

Langages spécifiques à un domaine — DSLs

- *3P* : programmabilité, portabilité, performance
- normalisation, basés sur des langages généralistes

Compilation efficace d'applications de traitement d'images pour processeurs manycore

CEA LIST, Saclay

Pierre Guillou

mardi 6 décembre 2016

MINES ParisTech, PSL Research University

Bibliographie personnelle I

Pierre Guillou. *Compilation d'applications de traitement d'images sur architecture MPPA-Manycore*. Conférence d'informatique en Parallélisme, Architecture et Système (ComPAS 2014). Poster. Avr. 2014. URL : https://hal-mines-paristech.archives-ouvertes.fr/hal-01096993.

Pierre Guillou. *Compiling Image Processing Applications for Many-Core Accelerators*. ACACES Summer School : Eleventh International Summer School on Advanced Computer Architecture and Compilation for High-Performance and Embedded Systems. Poster. Juil. 2015. URL : https://hal-mines-paristech.archives-ouvertes.fr/hal-01254412.

Bibliographie personnelle II

Pierre Guillou. `smilc` : *A C wrapper for SMIL*. URL : `https://scm.cri.ensmp.fr/git/smilc.git`.

Pierre Guillou, Fabien Coelho et François Irigoin. « Languages and Compilers for Parallel Computing : 27th International Workshop, LCPC 2014, Hillsboro, OR, USA, September 15-17, 2014, Revised Selected Papers ». In : sous la dir. de James Brodman et Peng Tu. Cham : Springer International Publishing, 2015. Chap. Automatic Streamization of Image Processing Applications, p. 224–238. ISBN : 978-3-319-17473-0. DOI : `10.1007/978-3-319-17473-0_15`. URL : `http://dx.doi.org/10.1007/978-3-319-17473-0_15`.

Bibliographie personnelle III

Pierre Guillou et al. « A Dynamic to Static DSL Compiler for Image Processing Applications ». In : *19th Workshop on Compilers for Parallel Computing*. Valladolid, Spain, juil. 2016. URL : https://hal-mines-paristech.archives-ouvertes.fr/hal-01352808.

Nelson Lossing, Pierre Guillou et François Irigoin. « Effects Dependence Graph : A Key Data Concept for C Source-to-Source Compilers ». In : *2016 IEEE 13th International Working Conference on Source Code Analysis and Manipulation (SCAM)* (oct. 2016).

Benoît Pin, Pierre Guillou et Fabien Coelho. **smiltofreia** : *A SMIL Python to FREIA C compiler*. URL : https://scm.cri.ensmp.fr/git/smilpyc.git.