

# Outline

- 1 Introduction au cours
  - Compilation et optimisations de codes
  - Des p'tites boucles, toujours des p'tites boucles
  - Exemples de spécificités architecturales
- 2 Pipeline logiciel
  - Sans contraintes de ressources
  - Compaction de boucles
  - Optimisations des durées de vie

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
    nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
    nop  
  sub.f r27, r25, r0  
  bne L400  
    nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
    ld[r26], r27  
        nop  
    add r27, 6740, r26  
    ld 0x1A54[r27], r27  
        nop  
    sub.f r27, r25, r0  
    bne L400  
        nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
    nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
    nop  
  sub.f r27, r25, r0  
  bne L400  
    nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
    ld[r26], r27  
        nop  
    add r27, 6740, r26  
    ld 0x1A54[r27], r27  
        nop  
    sub.f r27, r25, r0  
    bne L400  
        nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
    nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
    nop  
  sub.f r27, r25, r0  
  bne L400  
    nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
    ld[r26], r27  
        nop  
    add r27, #6740, r26  
    ld 0x1A54[r27], r27  
        nop  
    sub.f r27, r25, r0  
    bne L400  
        nop  
L399 :
```

# Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
    ld[r26], r27  
        nop  
    add r27, 6740, r26  
    ld 0x1A54[r27], r27  
        nop  
    sub.f r27, r25, r0  
    bne L400  
        nop  
L399 :
```

**8n** cycles.



## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
  nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
  nop  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

8n cycles.

## Code compaction

```
L400 :  
  ld[r26], r27  
  nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
  nop  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
  nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
  nop  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

8n cycles.

## Code compaction

```
L400 :  
  ld[r26], r27  
  nop  
  ld 0x1A54[r27], r27  
  add r27, 6740, r26  
  nop  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

## Sequential code

```
L400 :  
  ld[r26], r27  
  nop  
  add r27, 6740, r26  
  ld 0x1A54[r27], r27  
  nop  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

**8***n* cycles.

## Code compaction

```
L400 :  
  ld[r26], r27  
  nop  
  ld 0x1A54[r27], r27  
  add r27, 6740, r26  
  sub.f r27, r25, r0  
  bne L400  
  nop  
L399 :
```

**7***n* cycles.

## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

Sequential code	Code compaction	Software pipelining
L400 : <b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 <b>ld</b> 0x1A54[r27], r27 nop <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 :	L400 : <b>ld</b> [r26], r27 nop <b>ld</b> 0x1A54[r27], r27 <b>add</b> r27, 6740, r26 <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 :	L400 : <b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 <b>ld</b> 0x1A54[r27], r27 nop <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 :
<b>8n</b> cycles.	<b>7n</b> cycles.	

## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

Sequential code	Code compaction	Software pipelining
L400 : <b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 <b>ld</b> 0x1A54[r27], r27 nop <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 : <b>8n</b> cycles.	L400 : <b>ld</b> [r26], r27 nop <b>ld</b> 0x1A54[r27], r27 <b>add</b> r27, 6740, r26 <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 : <b>7n</b> cycles.	<b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 L400 : <b>ld</b> 0x1A54[r27], r27 nop <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 <b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 L399 :

## Software pipelining : example for LANai 3.0

Optimize **throughput**, with dependence & resource constraints.

Ex : sequential, pipelined LANai3.0, load & branch = one “shadow”.

Sequential code	Code compaction	Software pipelining
L400 : <b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 <b>ld</b> 0x1A54[r27], r27 nop <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 :	L400 : <b>ld</b> [r26], r27 nop <b>ld</b> 0x1A54[r27], r27 <b>add</b> r27, 6740, r26 <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 nop L399 :	<b>ld</b> [r26], r27 nop <b>add</b> r27, 6740, r26 L400 : <b>ld</b> 0x1A54[r27], r27 <b>ld</b> [r26], r27 <b>sub.f</b> r27, r25, r0 <b>bne</b> L400 <b>add</b> r27, 6740, r26 L399 :
<b>8</b> <i>n</i> cycles.	<b>7</b> <i>n</i> cycles.	<b>3</b> + <b>5</b> <i>n</i> cycles.

## Modèle(s) de processeurs

- Unités parfois pipelinées, parfois non-pipelinées, parfois plus complexes.
  - Unités spécifiques ou non.
  - Durée  $d$  d'une opération: deux significations.
    - durée d'utilisation de la ressource:  $d(u)$  pour une opération  $u$ .
    - délai entre deux opérations dépendantes:  $d(e)$  pour un arc  $e$ .
  - Distance de dépendances:  $w(e)$  pour un arc  $e$ .
  - Contraintes de registres.
- ☞ Modèle plus général = graphes avec délais sur sommets et arcs + tables d'utilisation des ressources (+ contraintes de registres).

## Ordonnancement cyclique (pipeline logiciel)

Trouver un ordonnancement  $t$  tel que:

- $\forall e = (u, v), \forall k \in \mathbb{N}, t(v, k) \geq t(u, k - w(e)) + d(u)$  (dépendances).
- Les contraintes de ressources sont satisfaites.
- $\lambda = \liminf_{k \rightarrow \infty} \frac{\max\{t(v, i) + d(v) \mid v \in V, i \leq k\}}{k}$  est minimal.

$\lambda$  est le **temps de cycle moyen** (ou l'“initiation interval”). On cherchera des ordonnancements cycliques:  $t(u, k) = \lambda k + \rho_u$ . Alors période = temps de cycle moyen.



## Bornes inférieures

Soit  $T = \max\{t(v, i) + d(v) \mid v \in V, i \leq k\}$ .

- Si on dispose de  $p$  ressources:  $pT \geq k \sum_{v \in V} d(v)$

$$\lambda \geq \frac{\sum_v d(v)}{p}$$

- Soit  $C$  un circuit.  $t(v, k) \geq t(v, k - w(C)) + d(C)$ , puis  $t(v, k) \geq t(v, k - \lfloor \frac{k}{w(C)} \rfloor w(C)) + \lfloor \frac{k}{w(C)} \rfloor d(C)$ . Donc  $T \geq \lfloor \frac{k}{w(C)} \rfloor d(C)$ . On en déduit:

$$\frac{T}{k} \geq \left(\frac{k}{w(C)} - 1\right) \frac{d(C)}{k} = \left(1 - \frac{w(C)}{k}\right) \frac{d(C)}{w(C)} \quad \Rightarrow \quad \lambda \geq \frac{d(C)}{w(C)}$$

Sans contrainte de ressources:  $\Rightarrow$

$$\lambda_\infty \geq \max\{\lceil \frac{d(C)}{w(C)} \rceil \mid C \text{ circuit}\}$$

## Ordonnements cycliques

**Ordonnement cyclique** de la forme  $\sigma(u, k) = \lambda k + \rho_u$ ,  $\lambda \in \mathbb{N}$ ,  $\rho_u \in \mathbb{N}$ .

**Dépendances**  $\sigma(v, k + w(e)) \geq \sigma(u, k) + d(u)$ , c'est-à-dire

$\rho_v + \lambda w(e) \geq \rho_u + d(u)$ . En sommant sur un circuit, on retrouve  $\lambda w(C) \geq d(C)$ .

**Astuce à la Bellman-Ford** Dans le graphe  $G'_\lambda = (V, E, w')$  avec  $w'(e) = d(u) - \lambda w(e)$  pour  $e = (u, v)$ , tous les circuits sont de poids négatif ou nul si et seulement si  $\lambda w(C) \geq d(C)$ .

## Calcul de $\lambda_\infty$ : complexité $O(|V|(|V| + |E|) \log(|V|d_{\max}))$

**Pour  $\lambda$  fixé** on construit le graphe  $G'_\lambda = (V, E, w')$  avec  
 $w'(e) = d(u) - \lambda w(e)$  si  $e = (u, v) \in E$ .

**Algorithme de Bellman-Ford** Si  $G'$  a un circuit de poids strictement positif alors  $\lambda$  est trop petit, sinon  $\lambda$  est trop grand.

**Recherche dichotomique** dans l'intervalle  $[0; \sum d(v)]$ .

**Pour  $\lambda_\infty$**  On note  $\rho_v$  le plus long chemin arrivant en  $v$  dans  $G'_\lambda$ . On a alors  
 $\rho_v \geq \rho_u + w'(e)$ , c'est-à-dire:

$$\rho_v + \lambda w(e) \geq \rho_u + d(u)$$


☞ l'ordonnancement cyclique  $\sigma(u, k) = \rho_u + \lambda k$  est optimal!

**Note** calculer  $\frac{d(C)}{w(C)}$  au lieu de  $\lceil \frac{d(C)}{w(C)} \rceil$  est possible mais plus compliqué.

# DAGs, “list scheduling” et borne de Graham

$T_l(p)$ : temps d'exécution d'un ordonnancement de liste pour  $p$  ressources.

- Pour tout chemin  $\mathcal{P}$ ,  $T_l(p) \geq d(\mathcal{P})$  (durée du chemin).
- “Surface” de calcul:  $pT_l(p) = \text{Idle time} + \text{Travail} (= \sum_{v \in V} d(v))$ .
- Il existe un chemin  $\mathcal{P}_0$  tel que  $\text{Idle time} \leq (p - 1)d(\mathcal{P}_0)$ .



Conséquence pour l'ordonnancement acyclique:

$$pT_l(p) \leq (p - 1)d(\mathcal{P}_0) + \sum_{v \in V} d(v)$$

$$\Rightarrow T_l(p) \leq \left(2 - \frac{1}{p}\right)T_{\text{opt}}(p)$$

## Borne de Graham pour l'ordonnancement de liste

$T_l(p)$ : temps d'exécution d'un ordonnancement de liste pour  $p$  ressources.

- Pour tout chemin  $\mathcal{P}$ ,  $T_l(p) \geq d(\mathcal{P})$  (durée du chemin).
- "Surface" de calcul:  $pT_l(p) = \text{Idle time} + \text{Travail} (= \sum_{v \in V} d(v))$ .
- Il existe un chemin  $\mathcal{P}_0$  tel que  $\text{Idle time} \leq (p - 1)d(\mathcal{P}_0)$ .

Conséquence pour l'ordonnancement acyclique

$$pT_l(p) \leq (p - 1)d(\mathcal{P}_0) + \sum_{v \in V} d(v)$$

$$\Rightarrow T_l(p) \leq (2 - \frac{1}{p})T_{\text{opt}}(p)$$

Conséquence sur la compaction de boucle

$$\lambda = T_l(p) \leq \frac{p-1}{p}d(\mathcal{P}_0) + \underbrace{\frac{\sum_{v \in V} d(v)}{p}}_{\leq \lambda_p}$$

$$\Rightarrow \lambda \leq (1 - \frac{1}{p})d(\mathcal{P}_0) + \lambda_p$$

## Différents types de stratégies de pipeline logiciel

**Simple compaction de boucles** avec expansion de scalaires. Très limité en présence de circuits (Ex : C2H, outil HLS d'Altera).

**Iterative modulo scheduling** B. Rau. Iterative modulo scheduling. Int. Journal of Parallel Programming, 24(1) :3-64, 1996. (Le “modulo scheduling” date de 1981, Rau & Glaeser)

**Decomposed software pipelining** Wang et Eisenbeis, PACT'93.

- ☛ Lien entre compaction de boucles, “decomposed software pipelining” et “retiming”.
- ☛ Variantes pour le “stage scheduling” (réorganisation pour modifier les durées de vie)

# Outline

- 1 Introduction au cours
  - Compilation et optimisations de codes
  - Des p'tites boucles, toujours des p'tites boucles
  - Exemples de spécificités architecturales
- 2 Pipeline logiciel
  - Sans contraintes de ressources
  - **Compaction de boucles et retiming**
  - Optimisations des durées de vie
- 3 Fusion de boucles
  - Intérêts et problèmes
  - Fusion de boucles simple : variantes
  - Fusion avec décalage

## Choix du décalage

Idée double:

- Minimiser le chemin critique pour la compaction.
  - ➡ Équivalent à minimiser la durée maximale d'un chemin n'ayant que des arcs de poids nul (**période d'horloge**). Algorithme de Leiserson et Saxe, complexité  $O(VE \log(V))$ .
- Minimiser le nombre de contraintes pour la compaction.
  - ➡ Équivalent à minimiser le **nombre d'arcs de poids nul**. Variante de l'algorithme out-of-kilter, complexité  $O(E^2)$  (version de base) ou  $O(V^2E)$  sous contrainte de période d'horloge.



# Retiming et circuits


**Correspondances** Décalage = retiming. Graphe = circuit.

$w(e)$  = nombre de registres sur l'arc  $e$ .  $d(u)$  = durée de l'opérateur  $u$ .

**Période d'horloge**  $\Phi(G)$  = durée maximale d'un chemin sans registres.

**Retiming** Fonction  $r : V \rightarrow \mathbb{Z}$  telle que, pour tout arc  $e = (u, v)$ ,

$w_r(e) = w(e) + r(v) - r(u) \geq 0$  (nombre positif de registres).



**But** Trouver  $r$  tel que  $\Phi(G_r)$  soit minimal.