Le Hachage Parfait Fait-il un Parfait Test de Sous-typage ?

Roland Ducournau

LIRMM
CNRS – Université Montpellier II

Langages et Modèles à Objets
Nîmes 2006

Plan

1. Contexte et Motivation
2. Du Hachage à la Perfection
   - Hachage Parfait
   - Application à JAVA
3. Expérimentations et évaluation
4. Comparaison, Conclusion et Perspective

LIRMM

Plan

1. Contexte et Motivation
2. Du Hachage à la Perfection
   - Hachage Parfait
   - Application à JAVA
3. Expérimentations et évaluation
4. Comparaison, Conclusion et Perspective

Implémentation des Objets

Mécanismes primitifs

- Appel de méthodes
- Accès aux attributs
- Test de sous-typage

Exigences d'efficacité et de fonctionnalité

- Temps constant
- Espace linéaire
- *Inlining*
- Héritage multiple
- Compilation modulaire et chargement dynamique

LIRMM

Héritage simple, typage statique

A

A

Héritage simple, typage statique

A

B

Problème : héritage multiple impossible

- Invariants de référence et de position
- Espace linéaire dans la taille de la relation de spécialisation
- Implémentation idéale

Héritage simple, typage statique

A

B

C

A		
A	B	
A	B	C

Problème : héritage multiple impossible

- Invariants de référence et de position
- Espace linéaire dans la taille de la relation de spécialisation
- Implémentation idéale

Coloration

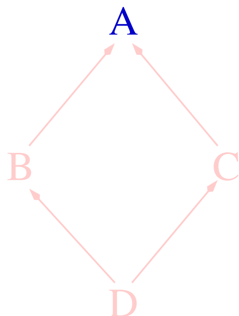

Coloration

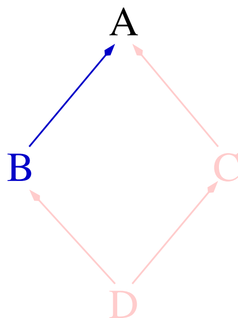

Problème : chargement dynamique impossible

- La coloration est une optimisation globale
- Invariants maintenus au prix de quelques trous

Coloration

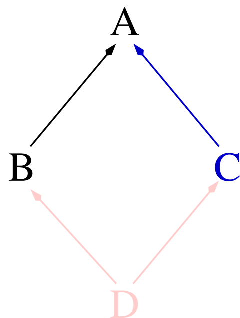

Problème : chargement dynamique impossible

- La coloration est une optimisation globale
- Invariants maintenus au prix de quelques trous

Coloration

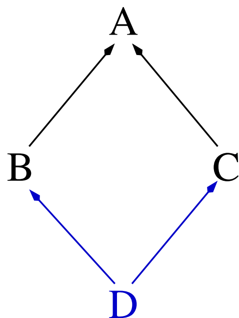

Problème : chargement dynamique impossible

- La coloration est une optimisation globale
- Invariants maintenus au prix de quelques trous

Accès direct dans une grande table

propriétés / superclasses (horizontally) — classes (vertically)

	a	b	c	d	e	f	g	h	i	j	k	l	...
A		x		x	x								
B		x	x				x	x					
C				x									
D							x				x		
E			x					x					
F				x									
...													

LIRMM

Accès direct dans une grande table

propriétés / superclasses →

classes ↓

	a	b	c	d	e	f	g	h	i	j	k	l	...
A		x		x	x								
B		x	x				x	x					
C				x									
D							x				x		
E			x					x					
F				x									
...													

Problème : espace non linéaire

Table gigantesque, presque vide

Tables de hachage

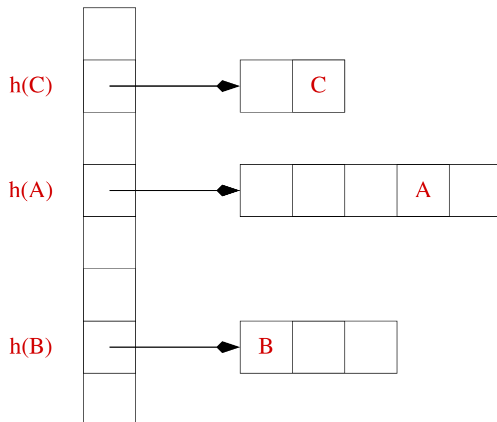

Tables de hachage

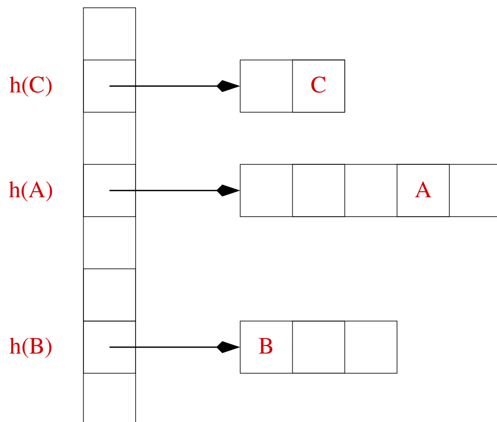

Problème : temps non constant

- recherche séquentielle à partir de la valeur de hachage
- efficacité spatiale médiocre (au moins $\times$ 2)

Question

Mais comment diable font-ils donc avec des tables de hachage ?

Plan

1. Contexte et Motivation
2. **Du Hachage à la Perfection**
   - Hachage Parfait
   - Application à JAVA
3. Expérimentations et évaluation
4. Comparaison, Conclusion et Perspective

LIRMM

Test de sous-typage par table de hachage

Principe

Soit 2 classes C et D, ou une classe C et un objet o :

- $D \prec C \iff id_C$ est trouvé dans la table de D
- $o \in C \iff id_C$ est trouvé dans la table de o

Test de sous-typage par table de hachage

Principe

Soit 2 classes C et D, ou une classe C et un objet o :

- $D \prec C \iff id_C$ est trouvé dans la table de D
- $o \in C \iff id_C$ est trouvé dans la table de o

Particularité

Au chargement de la classe D, toutes ses super-classes sont connues.

- plus besoin d'ajout, ni de retrait
- $\Rightarrow$ La table de D peut être optimisée statiquement

Test de sous-typage par table de hachage

Principe

Soit 2 classes C et D, ou une classe C et un objet o :

- $D \prec C \iff id_C$ est trouvé dans la table de D
- $o \in C \iff id_C$ est trouvé dans la table de o

Particularité

Au chargement de la classe D, toutes ses super-classes sont connues.

- plus besoin d'ajout, ni de retrait
- $\Rightarrow$ La table de D peut être optimisée statiquement

Solution : le "hachage parfait" [Sprugnoli 77]

- hachage sans collision
- temps constant, espace à déterminer

Hachage parfait

Principe

- un univers E,
- un ensemble $I \subset E$ à hacher,
- une fonction de hachage $h : E \rightarrow [0..H-1]$,
- une table T de taille H.

h est injective sur I $\Rightarrow$ $x \in I$ ssi $T[h(x)] = x$

Problème

Etant donné I, calculer h et H

LIRMM

Application au test de sous-typage

Pour chaque classe C

- $E = [0..N-1]$ ensemble des identifiants de classes
- $I_C = \{id_D \mid C \preceq D\}$
- fonction $h_C : [0..N-1] \rightarrow [0..H_C-1]$ injective sur I_C avec $h_C(x) = hash(x, H_C)$

Application au test de sous-typage

Pour chaque classe C

- $E = [0..N-1]$ ensemble des identifiants de classes
- $I_C = \{id_D \mid C \preceq D\}$
- fonction $h_C : [0..N-1] \rightarrow [0..H_C-1]$ injective sur I_C
  avec $h_C(x) = hash(x, H_C)$

Quelle fonction pour *hash* ?

- Exigences : mono-instruction, si possible mono-cycle
- Deux candidates naturelles :
  reste de division entière (mod) et conjonction booléenne (and)

LIRMM

Application au test de sous-typage

Pour chaque classe C

- $E = [0..N-1]$ ensemble des identifiants de classes
- $I_C = \{id_D \mid C \preceq D\}$
- fonction $h_C : [0..N-1] \rightarrow [0..H_C - 1]$ injective sur I_C
  avec $h_C(x) = hash(x, H_C)$

Quelle fonction pour $hash$?

- Exigences : mono-instruction, si possible mono-cycle
- Deux candidates naturelles :
  reste de division entière (mod) et conjonction booléenne (and)

Problème : calculer H_C minimal tq h_C soit injective ?

- algorithme polynomial facile

Applications

Test de sous-typage en C++

- ... ou dans tout langage en héritage multiple “pur”
- et avec chargement dynamique

Langage à la JAVA

... ou tout autre langage en sous-typage multiple
2 applications :

- test de sous-typage quand la cible est une interface
- appel de méthode quand le receveur est typé par une interface

LIRMM

Implémentation pour JAVA

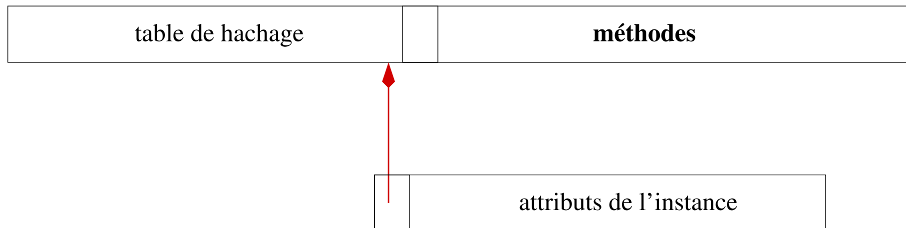

Table bidirectionnelle

- Partie positive pour les classes, comme en héritage simple
- Partie négative pour les interfaces, avec hachage parfait

Implémentation pour JAVA

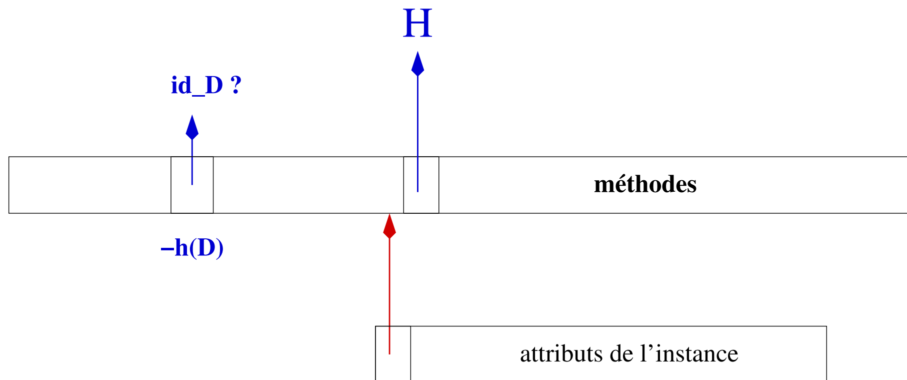

Table bidirectionnelle

- Test de sous-typage pour interfaces
- $o \in D$?

Implémentation pour JAVA

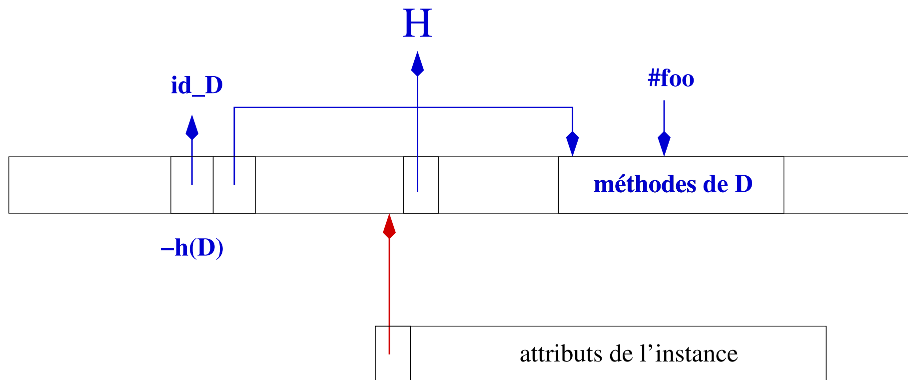

Table bidirectionnelle

- Appel de méthode pour interfaces (`invokeinterface`)
- `D x ; x.foo(arg)`

Motivation pour JAVA

JAVA normal

- utilisation fréquente des *downcasts*
  manque de généricité en 1.4
- et de `invokeinterface`
  suivant le style de programmation / conception

Langage SCALA

- JAVA + mixins
- compile → JVM ou DOTNET CRL
- les attributs sont médiatisés par des accesseurs
- tous les types sont des interfaces
- ⇒ `invokeinterface` est omniprésent

Plan

1. Contexte et Motivation
2. Du Hachage à la Perfection
   - Hachage Parfait
   - Application à JAVA
3. **Expérimentations et évaluation**
4. Comparaison, Conclusion et Perspective

Description de l'expérimentation

Benchmarks

- Famille de benchmarks classiques,
- utilisés depuis plus de 10 ans par l'ensemble de la communauté d'implémentation des objets
- 17 hiérarchies, plus de 30000 classes

Simulation

- Plate forme de simulation en LISP,
- utilisée depuis 2000 pour évaluer toutes les implémentations (C++, coloration, etc.)

LIRMM

Résultats pour JAVA

Espace et temps

technique	appel de méthode cycles		appel de méthode code	test sous-typage cycles		test sous-typage code	nég / pos
COL_2	$2L+B$	16	3	$2L+2$	8	4	ϵ
DA	$3L+B$	19	4	$2L+3$	9	7	4.2

Latences

- de chargement : $L = 3$
- de saut indirect : $B = 10$
- de division entière : $D = 6$

Résultats pour JAVA

Espace et temps

technique	appel de méthode cycles		appel de méthode code	test sous-typage cycles		test sous-typage code	nég / pos
COL_2	$2L+B$	16	3	$2L+2$	8	4	ϵ
DA	$3L+B$	19	4	$2L+3$	9	7	4.2
PH `and`	$4L+B+2$	24	7	$3L+4$	13	7	1.2
PH `mod`	$4L+B+D+1$	29	7	$3L+D+3$	18	7	0.4

Latences

- de chargement : $L = 3$
- de saut indirect : $B = 10$
- de division entière : $D = 6$

LIRMM

Résultats pour JAVA

Espace et temps

technique	appel de méthode cycles		code	test sous-typage cycles		code	nég / pos
COL_2	$2L+B$	16	3	$2L+2$	8	4	ϵ
DA	$3L+B+1$	20	5	$2L+3$	9	7	2.1
PH `and`	$4L+B+3$	25	8	$3L+4$	13	7	0.6
PH `mod`	$4L+B+D+1$	30	8	$3L+D+3$	18	7	0.2

Presqu'assez rapide, presqu'assez compact !

- adresses $\longrightarrow$ offsets :
  $\Rightarrow$ 1 cycle et 1 instruction en plus, espace divisé par 2
- $3 \leq D \leq 25$ cycles, suivant processeurs et données

LIRMM

Résultats pour JAVA

Espace et temps

technique	appel de méthode cycles		appel de méthode code	test sous-typage cycles		test sous-typage code	nég / pos
COL_2	$2L+B$	16	3	$2L+2$	8	4	ϵ
DA	$3L+B+1$	20	5	$2L+3$	9	7	2.1
PH and	$4L+B+3$	25	8	$3L+4$	13	7	0.6
PH mod	$4L+B+D+1$	49	8	$3L+D+3$	37	7	0.2

Presqu'assez rapide, presqu'assez compact !

- adresses $\longrightarrow$ offsets :
  $\Rightarrow$ 1 cycle et 1 instruction en plus, espace divisé par 2
- $3 \leq D \leq 25$ cycles, suivant processeurs et données

LIRMM

Plan

1. Contexte et Motivation
2. Du Hachage à la Perfection
   - Hachage Parfait
   - Application à JAVA
3. Expérimentations et évaluation
4. **Comparaison, Conclusion et Perspective**

Autres travaux

Test de sous-typage

- codage d'ordres (Ait-Kaci, Caseau, Habib, Vitek, Zibin, ..)
- efficace mais incompatible avec le chargement dynamique

En JAVA

- techniques *ad hoc* : hachage + cache
- taille constante $\Rightarrow$ espace mal optimisé et tests supplémentaires
- techniques dépareillées
- pas d'*inlining*
- mais efficacité statistique grâce au cache

Le hachage parfait se compare honorablement

- compatible avec chargement dynamique
- efficacité constante et plutôt bonne

Conclusion

Un test de sous-typage presque parfait

- temps constant assez petit
- espace pas trop grand
- séquence assez courte
- compatible héritage multiple et chargement dynamique

Une “invocation d’interface” presque parfaite

- pour les langages en sous-typage multiple
- avec une technique qui sert aux deux

Expérimentation réelle

... cherche machine virtuelle JAVA.

Perspective

Mais un test de sous-typage pas parfait

- PH and prend trop de place : dégradation marquée avec la taille
- la division entière n'est pas efficace en temps
- le temps de and pour l'espace de mod serait parfait !

Améliorations

- hachage *quasi-parfait* : décevant !
- PH + cache : 4 instructions + 2 cycles en plus
  ou $2L + 2$ cycles au lieu de $3L + D + 3$
- fonction *hash* à deux opérations mono-cycles
  - addition, décalage et opérations bit-à-bit
  - 1 cycle et 1 ou 2 instructions supplémentaires
  - pour un espace réduit de plus de moitié

Un dernier doute

Depuis 30 ans,
personne n'aurait songé à se servir du hachage parfait
pour implémenter les objets ? ? ?

LIRMM