Compilation

Cours n°2: Syntaxe, sémantique et interprétation de Pseudo-C

Sandrine Blazy
(d'après le cours de François Pottier)

ensiie - 2^e année

3 novembre 2008

école nationale supérieure d'informatique
pour l'industrie et l'entreprise

ensiie

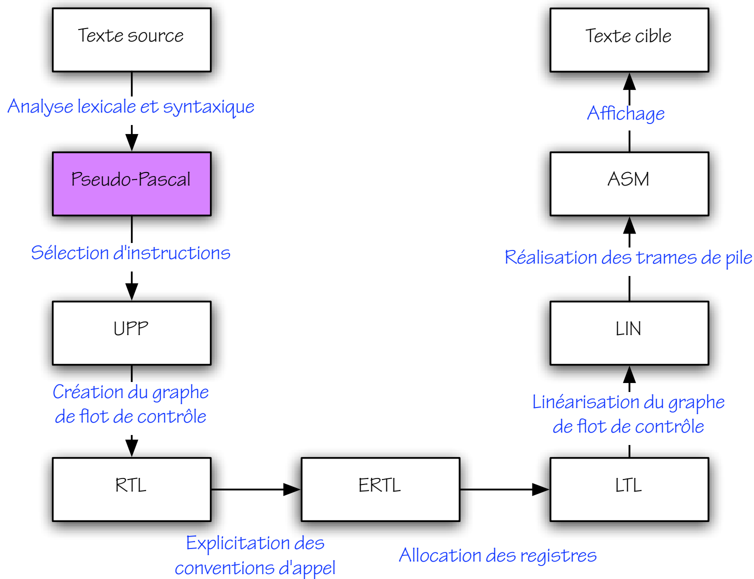

ensiie

1. Syntaxes concrète et abstraite

Syntaxe abstraite de Pseudo-C

Sémantique opérationnelle

Interprétation

ensiie

Syntaxes concrète et abstraite

Un *langage* de programmation est un ensemble de programmes.

En termes de *syntaxe concrète*, un programme est une *suite de caractères*. La syntaxe concrète spécifie comment les programmes s'écrivent « sur papier ».

En termes de *syntaxe abstraite*, un programme est un *arbre*. La syntaxe abstraite définit la structure idéale (mathématique) des programmes.

Syntaxes concrète et abstraite

Voici un fragment de syntaxe *concrète :*

$x1 := a * (x2 + b);$

Celui-ci correspond à un fragment de syntaxe *abstraite :*

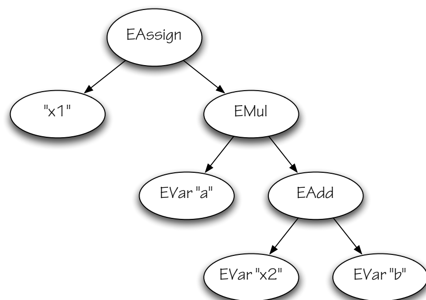

ensiie

Syntaxe concrète sur machine

Un programme en syntaxe concrète se présente sous forme de *suite de caractères :*

```
x1␣:=␣a␣*␣(x2␣+␣b);
```

ou bien, après *analyse lexicale*, sous forme de *flux de lexèmes :*

```
ID("x1") COLONEQ ID("a") TIMES LPAREN
ID("x2") PLUS ID("b") RPAREN SEMICOLON
```

Ce flux de lexèmes est transformé par *analyse syntaxique* en un arbre de syntaxe abstraite (cf. cours de Lex & Yacc).

ensiie

Syntaxe abstraite sur machine

Les arbres de syntaxe abstraite sont définis en Objective Caml sous forme d'un *type algébrique* :

```
type expr =
| EVar of string
| EAdd of expr * expr
| EMul of expr * expr
| EAssign of string * expr
| ...
```

L'arbre correspondant au fragment précédent s'écrit alors :

```
EAssign ("x1", EMul (EVar "a", EAdd (EVar "x2", EVar "b")))
```

ensiie

Syntaxe abstraite sur papier

Lorsqu'on raisonne *sur papier* à propos d'arbres de syntaxe *abstraite*, sous quelle forme les écrit-on ? Dessiner de petits arbres serait trop lourd. La notation Objective Caml est bien lourde également.

De ce fait, on emploie informellement la syntaxe *concrète* du langage pour dénoter des arbres de syntaxe *abstraite !* C'est ce que nous allons faire dans ce qui suit...

Syntaxes concrète et abstraite

2. Syntaxe abstraite de Pseudo-C

Sémantique opérationnelle

Interprétation

ensiie

Catégories

Pour définir Pseudo-C, nous allons définir toute une série de *catégories* syntaxiques : *types*, *constantes*, *opérateurs* unaires et binaires, *opérations primitives*, *cibles* d'appel, *expressions*, *conditions*, *instructions*, *définitions* de procédures ou fonctions, et enfin *programmes*.

La définition complète est résumée dans une fiche.

ensiie

Types

Les *valeurs* que Pseudo-C permet de manipuler sont les entiers, les booléens, et les tableaux de valeurs. Les *types* reflètent cette classification des valeurs.

$$
\begin{array}{lllll}
\tau & ::= & & & \textbf{types} \\
 & & | & \text{integer} & \text{entiers} \\
 & & | & \text{boolean} & \text{booléens} \\
 & & | & \text{array of } \tau & \text{tableaux}
\end{array}
$$

ensiie

Constantes

Les *constantes* sont booléennes ou entières. Il n'y a pas de constantes de type tableau : les tableaux sont alloués dynamiquement.

k	$::=$		**constantes**
	$\mid$	b	constante booléenne
	$\mid$	n	constante entière

Opérateurs

Des *opérateurs* unaires et binaires sont utilisés dans la construction des expressions.

uop	::=		**opérateurs unaires**
	$\mid$	$-$	négation
bop	::=		**opérateurs binaires**
	$\mid$	$+$	addition
	$\mid$	$-$	soustraction
	$\mid$	$\times$	multiplication
	$\mid$	$/$	division
	$\mid$	$< \mid \leq \mid > \mid \geq \mid = \mid \neq$	comparaison

ensiie

Opérations primitives

Le langage propose quelques opérations *primitives* (prédéfinies).

π	::=		**opérations primitives**
	|	write	affichage d'un entier
	|	writeln	affichage d'un entier et retour à la ligne
	|	readln	lecture d'un entier

La *cible* d'un appel de procédure ou fonction est soit primitive, soit définie par l'utilisateur.

φ	::=		**cible d'un appel**
	|	π	opération primitive
	|	f	procédure ou fonction définie par l'utilisateur

ensiie

Expressions, conditions et instructions

Pseudo-C distingue *expressions*, *conditions*, et *instructions*.

Cette distinction est *arbitraire*. On pourrait n'effectuer aucune distinction au niveau de la syntaxe abstraite et se reposer sur le *typage* pour effectuer les vérifications nécessaires.

Expressions

Les *expressions* sont définies ainsi :

e	$::=$		**expressions**
	$\mid$	k	constante
	$\mid$	x	variable
	$\mid$	uop e	application d'un opérateur unaire
	$\mid$	e bop e	application d'un opérateur binaire
	$\mid$	$\varphi(e\ \ldots\ e)$	appel de fonction
	$\mid$	$e[e]$	lecture dans un tableau
	$\mid$	new array of τ $[e]$	allocation d'un tableau

Conditions

Les *conditions* sont des combinaisons booléennes d'expressions :

c	$::=$		**conditions**
	$\mid$	e	expression (à valeur booléenne)
	$\mid$	not c	négation
	$\mid$	c and c	conjonction
	$\mid$	c or c	disjonction

ensiie

Instructions

Les *instructions* sont définies au-dessus des expressions et conditions :

i	$::=$		**instructions**
	$\mid$	$\varphi(e \ \ldots \ e)$	appel de procédure
	$\mid$	$x := e$	affectation
	$\mid$	$e[e] := e$	écriture dans un tableau
	$\mid$	$i \ \ldots \ i$	séquence
	$\mid$	if c then i else i	conditionnelle
	$\mid$	while c do i	boucle

Procédures et fonctions

Une *définition de fonction* nomme la fonction puis déclare ses *paramètres formels*, le type de son résultat, et ses *variables locales,* avant de donner le *corps* de la fonction.

d	$::=$		**définitions de procédures/fonctions**
	$\mid$	$f(x : \tau \ \ldots \ x : \tau) : \tau^?$	en-tête
		var $x : \tau \ \ldots \ x : \tau$	variables locales
		i	corps

Une définition de *procédure* est identique, excepté qu'une procédure n'a pas de résultat.

ensiie

Programmes

Un *programme* est composé de déclarations de *variables globales,* de déclarations de procédures ou fonctions, et d'un corps.

p	$::=$		**programme**
	$\mid$	var $x : \tau \; \ldots \; x : \tau$	variables globales
		$d \; \ldots \; d$	définitions de procédures/fonctions
		i	corps

ensiie

Expressivité et complétude

Même si la définition de sa syntaxe peut paraître longue, Pseudo-C est un langage *très réduit*. Il ne propose ni structures de données, ni fonctions de première classe, ni objets, ni exceptions...

Informellement, un langage est dit *expressif* s'il permet une écriture concise et élégante des algorithmes. En ce sens, Pseudo-C est *plus expressif* que l'assembleur MIPS, mais reste tout de même *peu expressif* comparé à Java ou Objective Caml.

Pseudo-C est *Turing-complet* : tout algorithme peut en principe être exprimé en Pseudo-C.

De la syntaxe à la sémantique

Nous avons défini la *structure* des programmes Pseudo-C, mais non leur *signification*. Que se passe-t-il lorsqu'un programme est exécuté ? Comment en prédire avec certitude le résultat ?

Il nous faut une sémantique *formelle*. Une simple description textuelle est imprécise et ne permet pas le raisonnement mathématique – comment *prouverons-nous* que notre compilateur est correct ?

ensiie

Syntaxes concrète et abstraite

Syntaxe abstraite de Pseudo-C

3 Sémantique opérationnelle

Interprétation

ensiie

Jugement principal

La sémantique de Pseudo-C est définie principalement par un *jugement* dont voici la forme :

$$p \longrightarrow$$

Ce jugement se lit : « le programme p s'exécute sans erreur et termine ».

La *non-terminaison* et les *erreurs* ne sont pas distinguées dans cette sémantique. Il serait possible de le faire.

Le *typage* interdit une grande partie des erreurs, mais pas toutes (tableau nil, dépassement de bornes de tableau).

Les *effets de bord* ne sont pas modélisés ici. Il serait possible de le faire.

ensiie

Jugements auxiliaires

Ce jugement principal est défini en termes de trois *jugements auxiliaires* dont voici la forme :

$$
\begin{array}{rcl}
G, H, E/e & \longrightarrow & G', H', E'/v \\
G, H, E/c & \longrightarrow & G', H', E'/b \\
G, H, E/i & \longrightarrow & G', H', E'
\end{array}
$$

Les *environnements* globaux et locaux G et E associent aux variables des valeurs. Le *tas* H associe aux adresses des suites finies de valeurs.

Valeurs

Les *valeurs* manipulées au cours de l'exécution sont définies ainsi :

v	$::=$		**valeurs**
	$\mid$	b	constante booléenne
	$\mid$	n	constante entière
	$\mid$	ℓ	adresse de tableau
	$\mid$	nil	adresse invalide

Les tableaux sont alloués dans le *tas* ; une variable de type tableau contient en fait une *adresse*.

ensiie

Dérivation de jugements

Un jugement est considéré comme vrai si et seulement s'il est *dérivable* de façon *finie* à partir d'un jeu fixé de *règles de déduction*. Il s'agit là d'un mécanisme de *définition inductive* (*cf.* cours de 1A).

Voici un exemple simpliste. Les jugements Pair n et Impair n pourraient être définis par les règles suivantes :

$$\textsc{Zéro}\quad \text{Pair } 0 \qquad\qquad \textsc{Successeur pair}\quad \frac{\text{Impair } n}{\text{Pair } n+1} \qquad\qquad \textsc{Successeur impair}\quad \frac{\text{Pair } n}{\text{Impair } n+1}$$

La barre horizontale se lit de haut en bas comme une *implication*. La meta-variable n est implicitement *universellement quantifiée*.

Règles

L'intégralité des règles qui définissent la sémantique de Pseudo-C est donnée par une fiche.

Deux pages de règles quelques peu cryptiques peuvent sembler une définition bien lourde, et pourtant Pseudo-C est *un langage très réduit* et très simple !

Voici quelques-unes de ces règles...

Constante

L'évaluation d'une *constante* est immédiate :

$$\frac{\textsc{Constante}}{S/k \longrightarrow S/k}$$

(Un *état* S est un triplet G, H, E.)

Accès aux variables

L'accès aux variables se fait à travers l'environnement approprié :

$$\textsc{Variable locale}\quad \frac{x \in \mathsf{dom}(E)}{G, H, E/x \longrightarrow G, H, E/E(x)}$$

$$\textsc{Variable globale}\quad \frac{x \in \mathsf{dom}(G) \setminus \mathsf{dom}(E)}{G, H, E/x \longrightarrow G, H, E/G(x)}$$

Si une variable globale et une variable locale portent le même nom, cette dernière *éclipse* la précédente.

Exemple : Pour $E = \{x \mapsto 1; y \mapsto 6; z \mapsto 8\}$, alors $\mathbf{dom}(E) = \{x; y; z\}$

ensiie

Affectation

L'affectation se fait en modifiant l'environnement approprié :

$$\textsc{Affectation: variable locale}\quad \frac{S/e \longrightarrow G', H', E'/v \qquad x \in \mathsf{dom}(E')}{S/x := e \longrightarrow G', H', E'[x \mapsto v]}$$

$$\textsc{Affectation: variable globale}\quad \frac{S/e \longrightarrow G', H', E'/v \qquad x \in \mathsf{dom}(G') \setminus \mathsf{dom}(E')}{S/x := e \longrightarrow G'[x \mapsto v], H', E'}$$

ensiie

Opérateurs

La sémantique des *opérateurs* est donnée par une fonction $[\![\cdot]\!]$ qui à chaque opérateur associe son interprétation en tant que fonction *partielle* des valeurs dans les valeurs.

Opérateur unaire

$$\frac{S/e \longrightarrow S'/v}{S/\mathsf{uop}\ e \longrightarrow S'/[\![\mathsf{uop}]\!](v)}$$

Opérateur binaire

$$\frac{S/e_1 \longrightarrow S'/v_1 \qquad S'/e_2 \longrightarrow S''/v_2}{S/e_1\ \mathsf{bop}\ e_2 \longrightarrow S''/[\![\mathsf{bop}]\!](v_1, v_2)}$$

L'évaluation des opérandes se fait *de gauche à droite*.

ensiie

Accès aux tableaux

L'accès à un tableau se fait en consultant le tas :

Lecture dans un tableau

$$\frac{S/e_1 \longrightarrow S'/\ell \qquad S'/e_2 \longrightarrow S''/n \qquad S'' = G'', H'', E'' \qquad H''(\ell) = v_0 \ldots v_{p-1} \qquad 0 \leq n < p}{S/e_1[e_2] \longrightarrow S''/v_n}$$

L'évaluation *échoue* si l'indice n est en dehors de l'intervalle $[0 \ldots p[$.

ensiie

Allocation d'un tableau

L'allocation d'un tableau se fait en ajoutant au tas une adresse *fraîche* ℓ, laquelle pointe vers un nouveau tableau de taille n :

$$\textsc{Allocation d'un tableau}\quad \frac{S/e \longrightarrow G', H', E'/n \qquad n \geq 0 \qquad \ell \# H' \qquad H'' = H'[\ell \mapsto \mathsf{default}(\tau)^n]}{S/\mathsf{new\ array\ of}\ \tau\ [e] \longrightarrow G', H'', E'/\ell}$$

Chaque case du tableau contient initialement une *valeur par défaut* de type τ.

Valeurs par défaut

La *valeur par défaut* d'une variable de type τ est définie ainsi :

$$\begin{array}{rcl} \text{default(boolean)} & = & \text{false} \\ \text{default(integer)} & = & 0 \\ \text{default(array of } \tau) & = & \text{nil} \end{array}$$

Cette notion est rendue nécessaire par le fait que Pseudo-C permet l'allocation de nouveaux emplacements mémoire sans exiger en même temps leur *initialisation.*

Appel de fonction

L'appel d'une fonction se fait en exécutant le corps de la fonction dans un *nouvel environnement* local, lequel *disparaît* lorsque la fonction rend la main :

Appel d'une fonction définie

$$\frac{\begin{array}{c} p \ni f(x_1 : \tau_1 \ \ldots \ x_n : \tau_n) : \tau \quad \text{var } x'_1 : \tau'_1 \ \ldots \ x'_q : \tau'_q \quad i \\ E' = (x_j \mapsto v_j)_{1 \leq j \leq n} \cup (x'_j \mapsto \text{default}(\tau'_j))_{1 \leq j \leq q} \cup (f \mapsto \text{default}(\tau)) \\ G, H, E'/i \longrightarrow G', H', E'' \qquad v = E''(f) \end{array}}{G, H, E/f(v_1 \ \ldots \ v_n) \longrightarrow G', H', E/v}$$

Le *résultat* de l'appel est lu dans la variable locale nommée f.

L'appel se fait *par valeur*.

ensiie

Conjonction

En Pseudo-C, l'évaluation de la conjonction et de la disjonction est *« à court-circuit : »*

Conjonction (si)

$$\frac{S/c_1 \longrightarrow S'/\mathsf{false}}{S/c_1 \text{ and } c_2 \longrightarrow S'/\mathsf{false}}$$

Conjonction (sinon)

$$\frac{S/c_1 \longrightarrow S'/\mathsf{true} \quad S'/c_2 \longrightarrow S''/b}{S/c_1 \text{ and } c_2 \longrightarrow S''/b}$$

Boucle

La sémantique des *boucles* est très simple :

$$\textsc{Boucle (si)}\quad \frac{S/c \longrightarrow S'/\mathsf{true} \qquad S'/e; \mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S''}{S/\mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S''}$$

$$\textsc{Boucle (sinon)}\quad \frac{S/c \longrightarrow S'/\mathsf{false}}{S/\mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S'}$$

ensiie

Syntaxes concrète et abstraite

Syntaxe abstraite de Pseudo-C

Sémantique opérationnelle

4 Interprétation

Sémantiques et interprètes

Cette sémantique constitue un interprète de Pseudo-C exprimé dans un langage de programmation *logique*, où la construction élémentaire est la règle de déduction.

Un interprète de Pseudo-C exprimé en Objective Caml constitue *également* une sémantique, quoique *moins élémentaire*, car s'appuyant sur la sémantique complexe d'Objective Caml.

En fait, écrire en Objective Caml un interprète de Pseudo-C est facile précisément parce qu'Objective Caml *contient* tout Pseudo-C : fonctions récursives, allocation dynamique de mémoire, tableaux, variables modifiables, etc.

Pourquoi écrire un interprète ?

Un interprète *examine* le programme source et le *simule* en même temps.

Un compilateur examine le programme source à *« compile time »* et engendre des instructions machine qui le simuleront à *« run time »*. Il y a *« staging »*, d'où plus grande efficacité.

Écrire un interprète ne nous aide pas écrire à un compilateur, sauf pour :

- mieux *comprendre* la sémantique du langage source ;
- *tester* le compilateur par comparaison avec l'interprète.