Compilation (INF 553)

Syntaxe, sémantique et interprétation de Pseudo-Pascal

François Pottier

31 janvier 2007

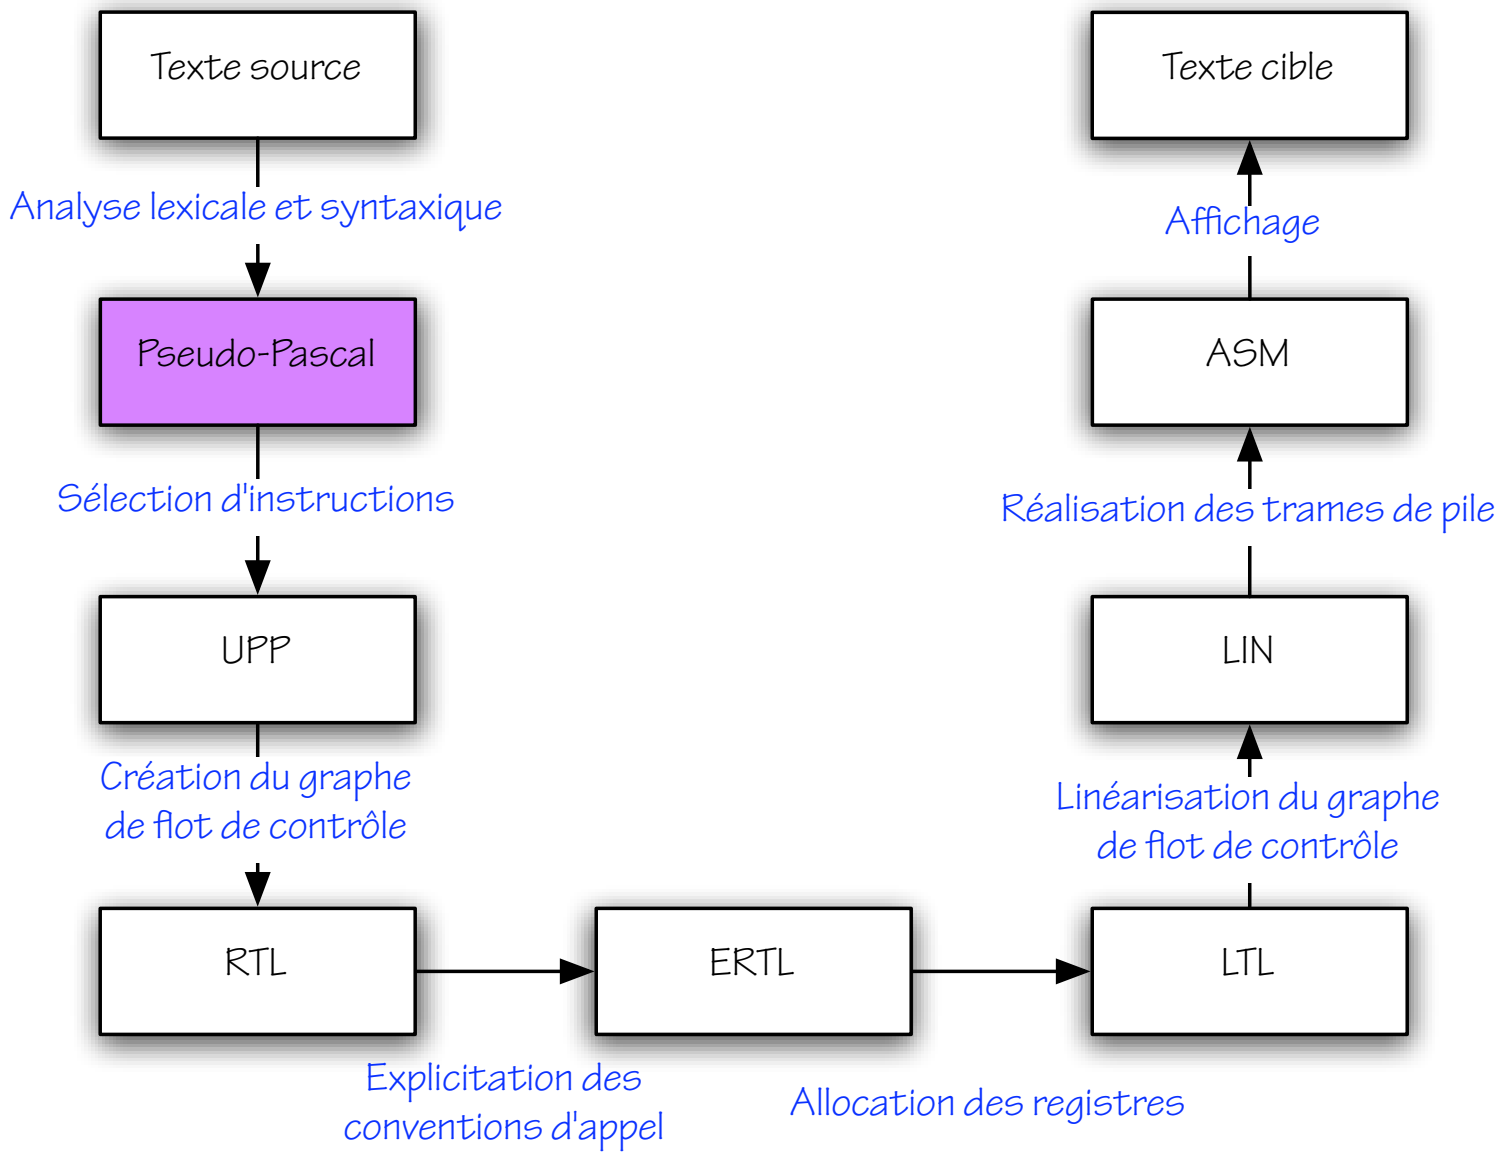
Texte source
Analyse lexicale et syntaxique
Pseudo-Pascal
Sélection d'instructions
UPP
Création du graphe de flot de contrôle
RTL
Explicitation des conventions d'appel
ERTL
Allocation des registres
LTL
Linéarisation du graphe de flot de contrôle
LIN
Réalisation des trames de pile
ASM
Affichage
Texte cible

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:*

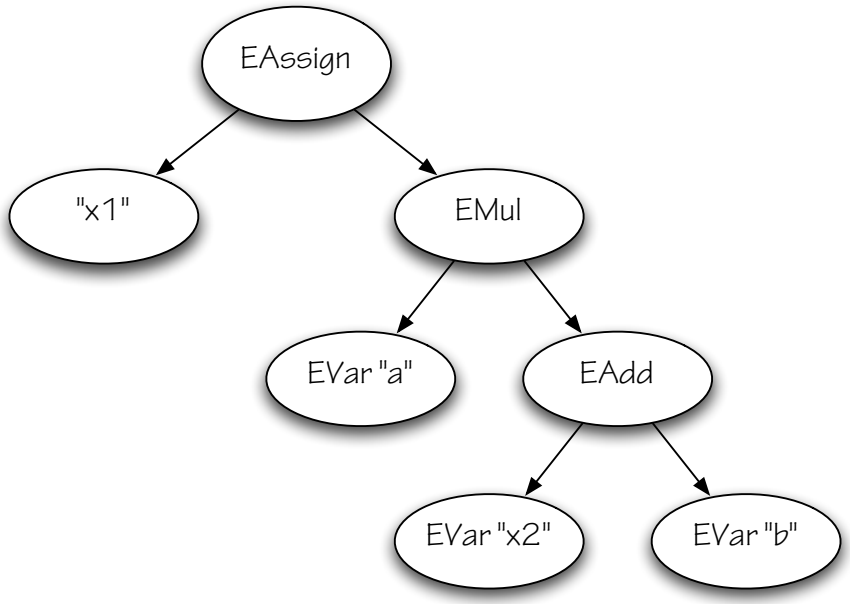

Syntaxe concrète sur machine

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

```
x 1 ␣ : = ␣ a ␣ * ␣ ( x 2 ␣ + ␣ 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 sera transformé par *analyse syntaxique* en un arbre de syntaxe abstraite (cf. prochain cours).

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")))
```

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...

Catégories

Pour définir Pseudo-Pascal, 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.

Types

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

τ	::=		**types**
		integer	entiers
	|	boolean	booléens
	|	array of τ	tableaux

Constantes

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

$$
\begin{array}{rcll}
k & ::= & & \textbf{constantes} \\
& | & b & \text{constante booléenne} \\
& | & n & \text{constante entière}
\end{array}
$$

Opérateurs

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

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

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

Expressions, conditions et instructions

Pseudo-Pascal 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
	$\mid$	$\mathit{uop}\ e$	application d'un opérateur unaire
	$\mid$	$e\ \mathit{bop}\ e$	application d'un opérateur binaire
	$\mid$	$\varphi(e \ldots e)$	appel de fonction
	$\mid$	$e[e]$	lecture dans un tableau
	$\mid$	$\mathsf{new\ array\ of}\ \tau\ [e]$	allocation d'un tableau

Conditions

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

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

Instructions

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

i	::=		**instructions**
	|	$\varphi(e \ldots e)$	appel de procédure
	|	$x := e$	affectation
	|	$e[e] := e$	écriture dans un tableau
	|	$i \ldots i$	séquence
	|	if c then i else i	conditionnelle
	|	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**
	|	$f(x:\tau \ldots x:\tau):\tau^?$	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.

Programmes

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

p	::=		**programme**
	|	$\mathtt{var}\ x : \tau \ldots x : \tau$	variables globales
		$d \ldots d$	définitions de procédures/fonctions
		i	corps

Expressivité et complétude

Même si la définition de sa syntaxe peut paraître longue, Pseudo-Pascal 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-Pascal est *plus expressif* que l'assembleur MIPS, mais reste tout de même *peu expressif* comparé à Java ou Objective Caml.

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

De la syntaxe à la sémantique

Nous avons défini la *structure* des programmes Pseudo-Pascal, 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 ?

Jugement principal

La sémantique de Pseudo-Pascal 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* (lecture et écriture sur l'entrée et la sortie standard) ne sont pas modélisés ici. Il serait possible de le faire.

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**
		b	constante booléenne
	|	n	constante entière
	|	ℓ	adresse de tableau
	|	nil	adresse invalide

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

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*.

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

Zéro

$$\text{Pair } 0$$

Successeur pair

$$\frac{\text{Impair } n}{\text{Pair } n+1}$$

Successeur impair

$$\frac{\text{Pair } n}{\text{Impair } n+1}$$

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

Règles

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

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

Voici quelques-unes de ces règles...

Constante

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

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:

$$\frac{x \in dom(E)}{G, H, E/x \longrightarrow G, H, E/E(x)}\ \text{Variable locale} \qquad \frac{x \in dom(G) \setminus dom(E)}{G, H, E/x \longrightarrow G, H, E/G(x)}\ \text{Variable globale}$$

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

Affectation

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

Affectation: variable locale

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

Affectation: variable globale

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

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

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

Opérateur binaire

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

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

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 $[0 \ldots p[$.

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:

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

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:

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

Cette notion est rendue nécessaire par le fait que Pseudo-Pascal 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*.

Conjonction

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

Conjonction (si)

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

Conjonction (sinon)

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

Boucle

La sémantique des *boucles* est très simple:

Boucle (si)

$$\frac{S/c \longrightarrow S'/\mathsf{true} \qquad S'/e;\mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S''}{S/\mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S''}$$

Boucle (sinon)

$$\frac{S/c \longrightarrow S'/\mathsf{false}}{S/\mathsf{while}\ c\ \mathsf{do}\ e \longrightarrow S'}$$

Sémantiques et interprètes

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

Un interprète de Pseudo-Pascal 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-Pascal est facile précisément parce qu'Objective Caml *contient* tout Pseudo-Pascal: fonctions récursives, allocation dynamique de mémoire, tableaux, variables modifiables, etc.

Vers un interprète en Objective Caml

Les environnements G et E associent des valeurs aux noms de variables et sont *modifiables*. On définit donc:

```
type environment = value ref StringMap.t
```

Le tas H est *simulé* par le tas Objective Caml et n'est donc pas explicitement représenté.

Un environnement D *immuable* associe des définitions aux noms de procédures ou fonctions. On pose:

```
type definitions = PP.procedure StringMap.t
```

Vers un interprète en Objective Caml

Les fonctions centrales de l'interprète sont paramétrées par D, G, et E. On définit une abréviation:

```
type 'a interpreter =
    definitions → environment → environment → 'a
```

Les fonctions qui interprètent expressions, conditions et instructions ont alors les types:

```
val interpret_expression : (PP.expression → value) interpreter
val interpret_condition : (PP.expression → bool) interpreter
val interpret_instruction : (PP.instruction → unit) interpreter
```

Quelques modules utiles

Voici les modules du « petit compilateur » dont vous aurez besoin en TD:

- *MIPSOps* définit entre autres les opérateurs binaires de Pseudo-Pascal;
- *Primitive* définit les opérations primitives de Pseudo-Pascal;
- *PP* définit la syntaxe abstraite de Pseudo-Pascal;
- *Integer* définit les opérations courantes sur les entiers 32 bits;
- *StringMap* définit des tables d'association dont les clefs sont des chaînes de caractères.

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.