Machines Virtuelles – MV6
Séance 4

Peter Habermehl
(Merci à Michele Pagani et ...)

Université Paris Cité
UFR Informatique
IRIF

Peter.Habermehl@irif.fr

22 Février 2024

Solution TP3: compil avec variables

```
let compil e =
  let succ = List.map (fun (k,v) -> (k,v+1)) in
  let rec aux e env =
    match e with
    | Const v ->
      [Consti (repr v)]
    | Unop (Succ, e) ->
      (aux e env) @ [Push; Consti 1; Addi]
    | Binop (Plus, e1, e2) ->
      (aux e1 env) @ [Push] @ (aux e2 (succ env)) @ [Addi]
    | Var x -> [Acc (List.assoc x env)]
    | Let (x,e1,e2) ->
      let l1 = aux e1 env in
      let l2 = aux e2 ((x,0)::((succ env))) in
      l1 @ [Push] @ l2 @ [Popi 1]
    | If (e1, e2, e3) ->
      let l1 = aux e1 env in
      let l2 = aux e2 env in
      let l3 = aux e3 env in
      l1 @ [Branchif (List.length l3 +2)]
      @ l3 @ [Branch (List.length l2+1)] @ l2
    | _ -> failwith "Students, this is your job !"
  in
  aux e []
```

Résumé

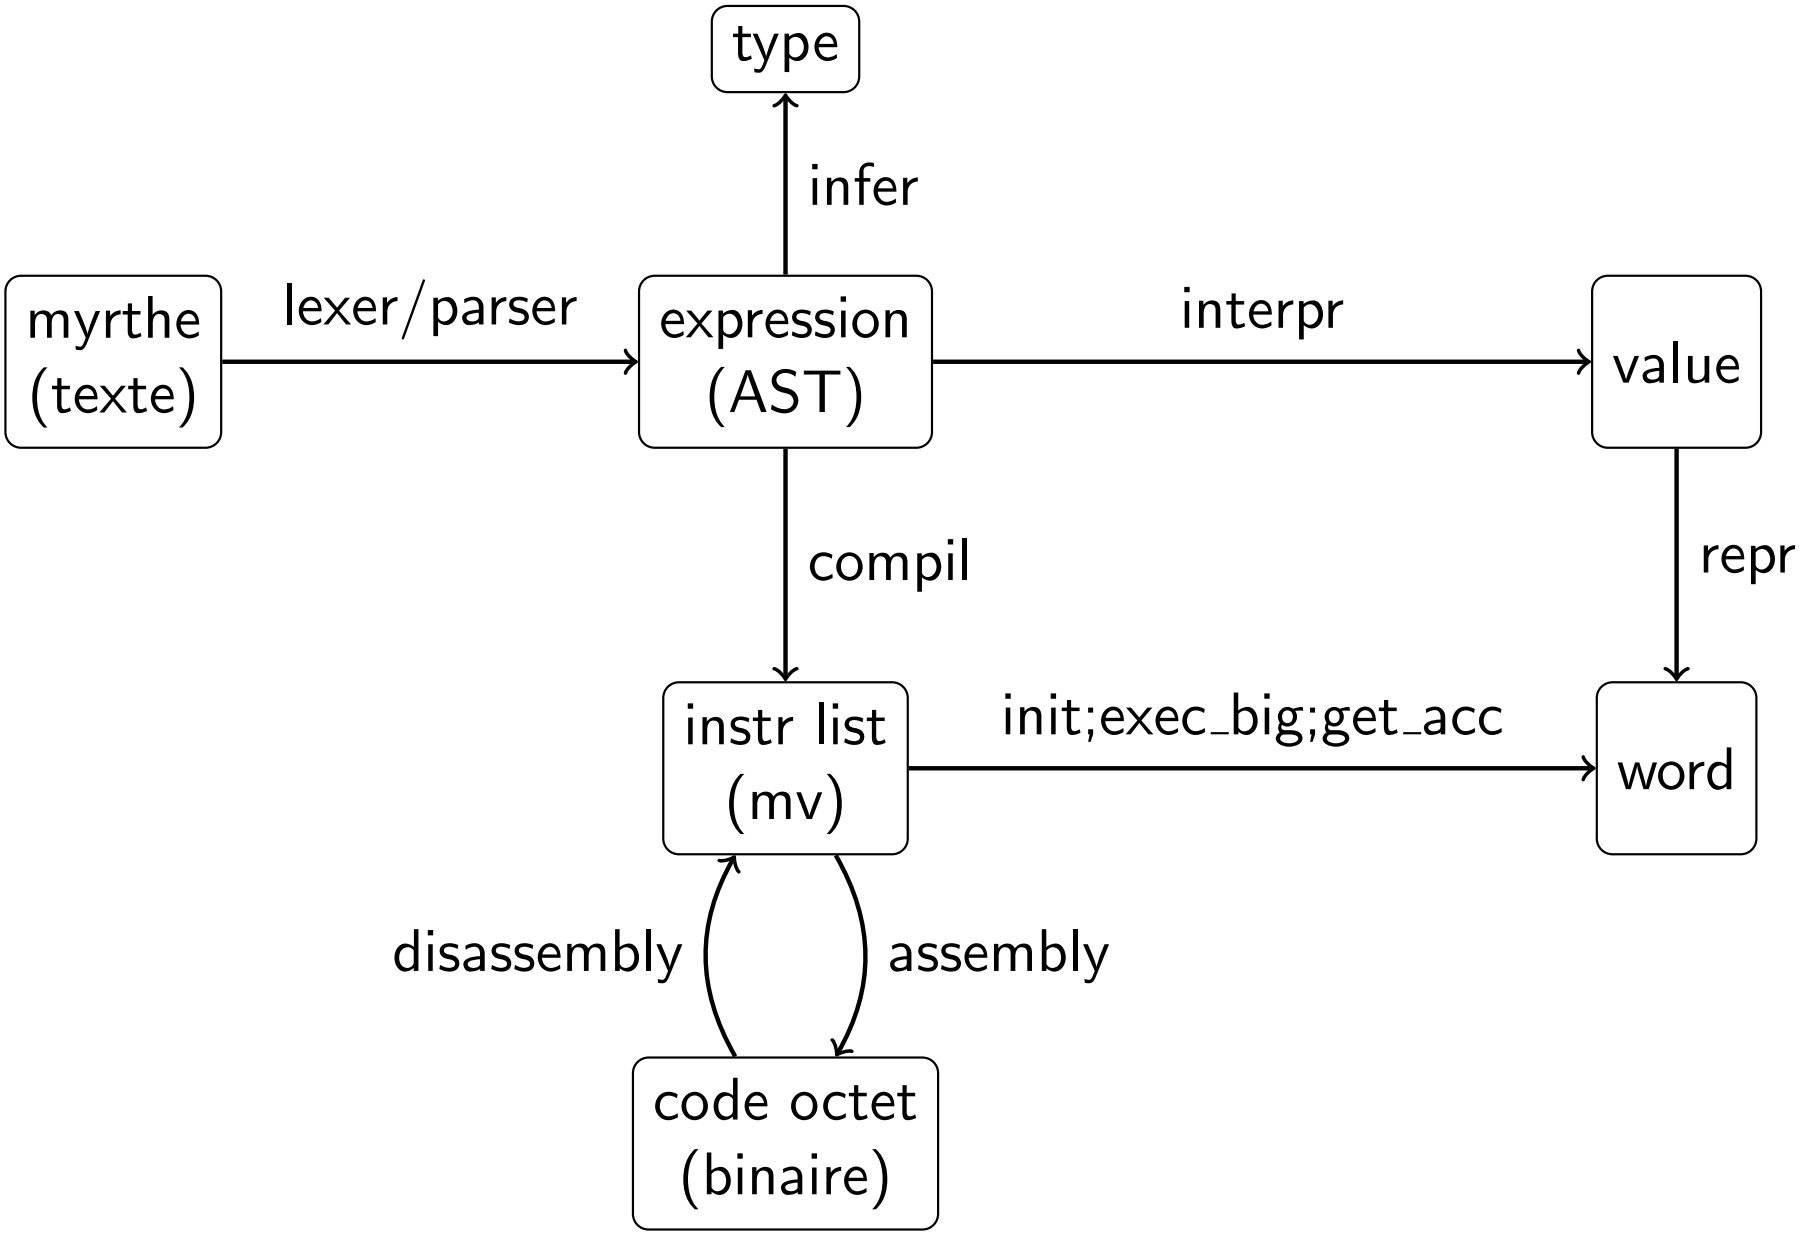
type
infer
myrthe
(texte)
lexer/parser
expression
(AST)
interpr
value
compil
repr
instr list
(mv)
init;exec_big;get_acc
word
disassembly
assembly
code octet
(binaire)

de Myrthe à OCaml

$$
\begin{array}{rcl}
\textit{unop} & ::= & \texttt{not} \mid \texttt{++} \\
\textit{binop} & ::= & \texttt{+} \mid \texttt{*} \mid \texttt{\&\&} \mid \texttt{||} \mid \texttt{=} \mid \texttt{<=} \\
\textit{expression} & ::= & \text{value} \\
& \mid & \textit{unop expression} \\
& \mid & \textit{expression binop expression} \\
& \mid & \texttt{if } \textit{expression} \texttt{ then } \textit{expression} \texttt{ else } \textit{expression} \\
& \mid & \text{var\_id} \\
& \mid & \texttt{let } \text{var\_id} \texttt{ = } \textit{expression} \texttt{ in } \textit{expression} \\
& \mid & \texttt{(} \textit{expression} \texttt{)}
\end{array}
$$

Question :

qu'est-ce qu'il manque pour avoir un vrai langage fonctionnel ?

de Myrthe à OCaml

unop ::= `not` | `++`

binop ::= `+` | `*` | `&&` | `||` | `=` | `<=`

expression ::= value
| *unop expression*
| *expression binop expression*
| `if` *expression* `then` *expression* `else` *expression*
| var_id
| `let` var_id `=` *expression* `in` *expression*
| `(` *expression* `)`

Question :

qu'est-ce qu'il manque pour avoir un vrai langage fonctionnel ?

- données structurées (types algébriques, tableaux, etc...)
- définition des functions, applications

de Myrthe à OCaml

$$
\begin{array}{rcl}
\textit{unop} & ::= & \texttt{not} \mid \texttt{++} \\
\textit{binop} & ::= & \texttt{+} \mid \texttt{*} \mid \texttt{\&\&} \mid \texttt{||} \mid \texttt{=} \mid \texttt{<=} \\
\textit{expression} & ::= & \text{value} \\
& \mid & \textit{unop expression} \\
& \mid & \textit{expression binop expression} \\
& \mid & \texttt{if } \textit{expression} \texttt{ then } \textit{expression} \texttt{ else } \textit{expression} \\
& \mid & \text{var\_id} \\
& \mid & \texttt{let } \text{var\_id} \texttt{ = } \textit{expression} \texttt{ in } \textit{expression} \\
& \mid & \texttt{(} \textit{expression} \texttt{)}
\end{array}
$$

Question :

qu'est-ce qu'il manque pour avoir un vrai langage fonctionnel ?

- données structurées (types algébriques, tableaux, etc...)
- définition des functions, applications

Pour traiter ce type de données il faut une MV avec un tas.

ocamlrun
la machine virtuelle de OCaml

Rappel

Il existe (au moins) deux compilateurs pour le langage OCaml

`ocamlopt` compile vers du code natif
(IA-32, IA-64, AMD64, PowerPC, SPARC, MIPS, ARM,...)

`ocamlc` compile vers du code-octet (`.cmo`)
OCAMLRUN

(autres compilateurs: `ocamljava`, `js_of_ocaml`, ...)

La machine virtuelle `ocamlrun`:

- machine à a-pile + tas
- représentation mémoire homogène des données
- les fonctions sont des données
- son code-octet `.cmo`

Le format de code-octet .cmo

Compilons le fichier `test.ml`:

```
1 let f x = x*10
2 let g y = (f (f y))
```

avec

```
ocamlc test.ml
```

Le format de code-octet .cmo

On obtient le fichier `test.cmo`.

Avec la commande `xxd test.cmo`:

```
00000000: 4361 6d6c 3139 3939 4f30 3238 0000 0084  Caml1999O028....
00000010: 5400 0000 0d00 0000 0000 0000 1a00 0000  T...............
00000020: 2100 0000 1a00 0000 2500 0000 0200 0000  !.......%.......
00000030: 6700 0000 0a00 0000 0b00 0000 7000 0000  g...........p...
00000040: 2800 0000 0100 0000 2b00 0000 0000 0000  (.......+.......
00000050: f8ff ffff 0a00 0000 2b00 0000 0100 0000  ........+.......
00000060: eeff ffff 0a00 0000 0c00 0000 4000 0000  ............@...
00000070: 0000 0000 1300 0000 0200 0000 3900 0000  ............9...
00000080: 0000 0000 8495 a6be 0000 007a 0000 0014  ...........z....
00000090: 0000 004d 0000 0042 0800 0028 0024 5465  ...M...B...(.$Te
000000a0: 7374 5000 74a0 a092 9204 0500 7040 a0a0  stP.t.......p@..
000000b0: 0407 9030 cd22 6fa5 1046 9349 dc9c 0e7b  ...0."o..F.I...{
000000c0: 6f41 0898 a0a0 2653 7464 6c69 6290 30c2  oA....&Stdlib.0.
000000d0: 1c5d 2641 6461 b543 3218 72a5 51ea 0da0  .]&Ada.C2.r.Q...
000000e0: a038 4361 6d6c 696e 7465 726e 616c 466f  .8CamlinternalFo
000000f0: 726d 6174 4261 7369 6373 9030 3a3c a183  rmatBasics.0:<..
00000100: 8627 f776 2f49 679c e027 8ad1 4040 4040  .'.v/Ig..'..@@@@
00000110: 4040                                     @@
```

Le format de code-octet .cmo

- Il existe une spécification du format .cmo:

  `http://cadmium.x9c.fr/distrib/caml-formats.pdf`

- Il existe aussi des outils pour désassembler leur contenu :

  `ocamldumpobj` affiche la description textuelle des instructions
  `ocamlobjinfo` affiche des informations supplémentaires

- On peut même demander au compilateur d'afficher le code produit:

```
$ ocamlc -c -dinstr test.ml
$ ocaml -dinstr
```

Le format de code-octet .cmo

```
$ ocamlc -dinstr test.ml
     branch L3
L1:  acc 0
     push
     envacc 1
     apply 1
     push
     envacc 1
     appterm 1, 2
L2:  const 10
     push
     acc 1
     multint
     return 1
L3:  closure L2, 0
     push
     acc 0
     closure L1, 1
     push
     acc 0
     push
     acc 2
     makeblock 2, 0
     pop 2
     setglobal Test!
```

Ocamlrun: état

Son état est constitué de:

- un programme (liste de bytecode)
- une pile `S`
- un tas `H` (heap) où placer les données allouées
- et sept registres:
  1. `pc`: *program counter* (adresse de la prochaine instruction)
  2. `accu`: *accumulator*
  3. `sp`: *stack pointer*
  4. `env`: *environment pointer* (pour la fermeture courante des fonctions)
  5. `extraArgs`: (nombre d'arguments en plus d'une application)
  6. `global`: (pour des données globales)
  7. `trapSp`: (pour le gestionnaire d'exceptions)

Ocamlrun: jeu d'instructions

Il y a presque 150 instructions,

- la plus part sont des variants similaires
- la description complète se trouve sur:

  `http://cadmium.x9c.fr/distrib/caml-instructions.pdf`

On va les regrouper en 3 parties

1. le fragment commun à Myrthe
   (gestion de la pile, arithmétique, branchement);
2. la représentation des données structurées;
3. la manipulation des fonctions.

Ocamlrun: jeu d'instructions

Il y a presque 150 instructions,

- la plus part sont des variants similaires
- la description complète se trouve sur:

  `http://cadmium.x9c.fr/distrib/caml-instructions.pdf`

On va les regrouper en 3 parties

1. le fragment commun à Myrthe
   (gestion de la pile, arithmétique, branchement);
2. la représentation des données structurées;
3. la manipulation des fonctions.

Ocamlrun: représentation des valeurs immédiates

Toute valeur OCaml est représentée par un mot machine (32/64 bits). Son premier bit détermine son utilisation:

- si c'est 1, il représente une valeur immédiate (codée sur 31/63 bits)
- si c'est 0, il représente un pointeur vers un bloc (données structurées, fonctions, cf. plus loin)

Représentation des valeurs immédiates par des mots 31/63 bits:

`int`	entier signé
`char`	entier correspondant au code ASCII
`bool`	`false` est codé par `0`, `true` par `1`
`unit`	`()` est codé par `0`

Ocamlrun: gestion de la pile

`push`	empile `accu`
`pop n`	dépile n éléments du sommet de S (c'est tout)
`acc n`	copie dans `accu` la valeur du n-ème élément de S

Variantes:

`acc0,..., acc7`	instructions spécialisées pour $n \leq 7$
`pushacc n`	même effet que `push; acc n`
`pushacc0...`	cf. `acc0` ... `acc7`
`assign n`	déplace `accu` dans la n-ème case de S (il vaut `()` après)

Ocamlrun: arithmétique

`constint n` met n dans `accu`

Avec des variantes:

`const0 ...const3` constint spécialisés pour n ≤ 3

`pushconstint n` même effet que `push;constint n`

`pushconstint0 ...3` cf. `pushconstint n`

`offsetint n` incrémente `accu` de n

`negint` accu reçoit l'opposé de sa valeur

`addint` accu reçoit `accu` + sommet de S (qui est dépilé)

`subint, mulint, divint, modint, andint, orint, (u)ltint...`

sont des opérateurs binaires qui fonctionnent de la même manière que `addint`.

`ltint, leint, gtint, geint...` sont des comparaisons.

Ocamlrun: branchements

Le saut se fait par décalage (offset), mais utilisation de `labels`

`branch n` saute n instructions en avant (ou en arrière si n < 0)

`branchif n` saute n instructions si `accu` $= 1$

`branchifnot n` saute n instructions si `accu` $= 0$

`beq m n` saute n instructions si `accu` $=$ m

`bneq`, `b(u)ltint`, `bleint`, `bgtint`, `b(u)geint` sont des sauts conditionnels binaires qui fonctionnent de la même façon que beq

Quiz: devine l'expression !

Quelle expression génère les code-octets suivants:

```
    const 3
    offsetint 4
    offsetint -2
    return 1
```

```
    const 3
    push
    const 2
    eqint
    branchifnot L1
    const 4
    return 1
L1: const 0
    return 1
```

Quiz: devine l'expression !

Quelle expression génère les code-octets suivants:

```
    const 3
    offsetint 4
    offsetint -2
    return 1
```

Solution:

$3+4-2$

```
    const 3
    push
    const 2
    eqint
    branchifnot L1
    const 4
    return 1
L1: const 0
    return 1
```

---

if $3 = 2$ **then** 4 **else** 0

Quiz: devine l'expression !

Quelle expression génère les code-octets suivants:

```
const 3
push
const 2
push
acc 0
push
acc 2
addint
return 3
```

Solution:

$$\textbf{let } x = 3 \textbf{ in let } y = 2 \textbf{ in } x + y$$

Quiz: devine l'expression !

Quelle expression génère les code-octets suivants:

```
const 3
push
const 2
push
acc 0
push
acc 2
addint
return 3
```

Solution:

let x = 3 **in** **let** y = 2 **in** x + y

Ocamlrun: jeu d'instructions

Il y a presque 150 instructions,

- la plus part sont des variants similaires
- la description complète se trouve sur:

  `http://cadmium.x9c.fr/distrib/caml-instructions.pdf`

On va les regrouper en 3 parties

1. le fragment commun à Myrthe
   (gestion de la pile, arithmétique, branchement);
2. la représentation des données structurées;
3. la manipulation des fonctions.

Ocamlrun: jeu d'instructions

Il y a presque 150 instructions,

- la plus part sont des variants similaires
- la description complète se trouve sur:

  `http://cadmium.x9c.fr/distrib/caml-instructions.pdf`

On va les regrouper en 3 parties

1. le fragment commun à Myrthe
   (gestion de la pile, arithmétique, branchement);
2. la représentation des données structurées;
3. la manipulation des fonctions.

Données structurées

En OCaml, on a plus que les types `int`, `bool` et `unit` : on a aussi

- les n-uplets `(x,y,z,...)`
- les enregistrements {`nom = "Alice"; age = 9`}
- les tableaux `[|1,2,3,4,...|]`
- les chaines de caractères `"abc"`
- les fonctions
- les types algebriques: listes, mais aussi tout type défini par l'utilisateur:
  `type t = A | B | M of t*t | N of t`

Les valeurs de tous ces types sont représentées en mémoire sur le tas (en angl. heap).

Qu'est-ce que le tas?

À un nouveau processus est assigné par l'OS

- un espace mémoire constant pour stocker son code
- un espace pour ses données constantes (string etc.)
- un espace de pile extensible (mais contigu)
- à la demande, de l'espace utilisateur (`malloc`, `free`)

La zone mémoire pointée par le retour de `malloc` fait partie du tas. Le processus est chargé de la libérer après utilisation.
On mime cela dans la MV.

Données structurées = bloc + pointeur

Par example, la donnée `('a', 'b')` est représenté par:

Un bloc de trois cases contiguës dans le tas:

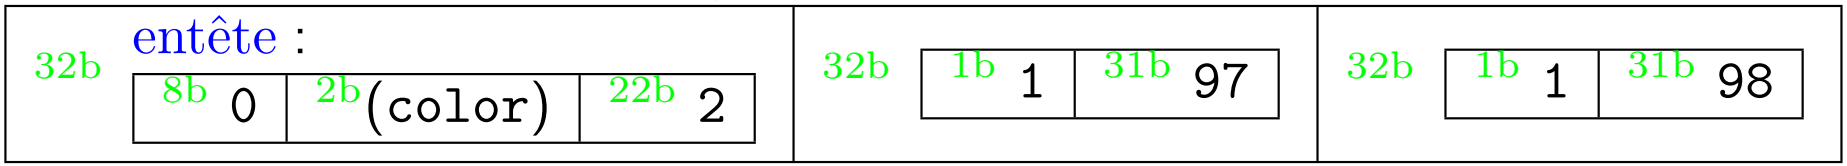

adresse dans le tas: `0x0143`

et un pointeur (adresse) vers la premier case de ce bloc :

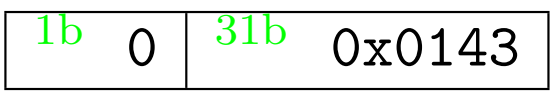

Données structurées = bloc + pointeur

Par example, la donnée `('a', 'b')` est représenté par:

Un bloc de trois cases contiguës dans le tas:

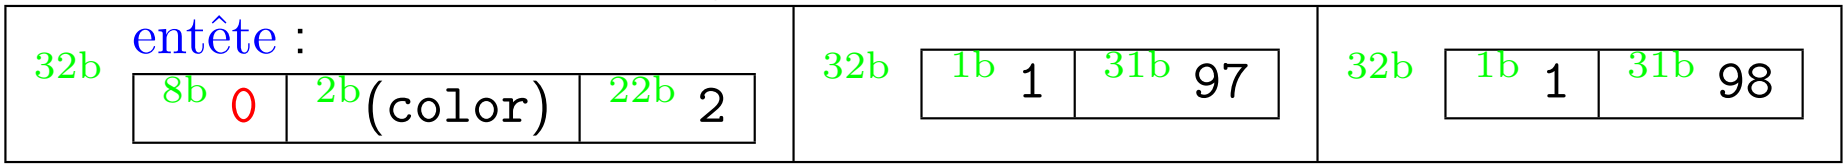

adresse dans le tas: `0x0143`

- tag : type de donnée,
  ex. string $\mapsto$ 252, float $\mapsto$ 253, fonction $\mapsto$ 247, n-uplet,
  enregistrements et tableau $\mapsto$ 0, types somme $\mapsto$ 0-245
- color : pour le ramasse miettes
- size : nombre cases bloc en plus de l'entête (valeurs à l'intérieur de la donnée structurée)

et un pointeur (adresse) vers la premier case de ce bloc :

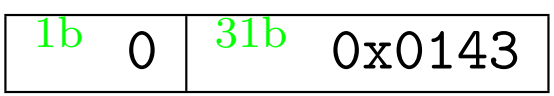

Données structurées = bloc + pointeur

Par example, la donnée `('a', 'b')` est représenté par:

Un bloc de trois cases contiguës dans le tas:

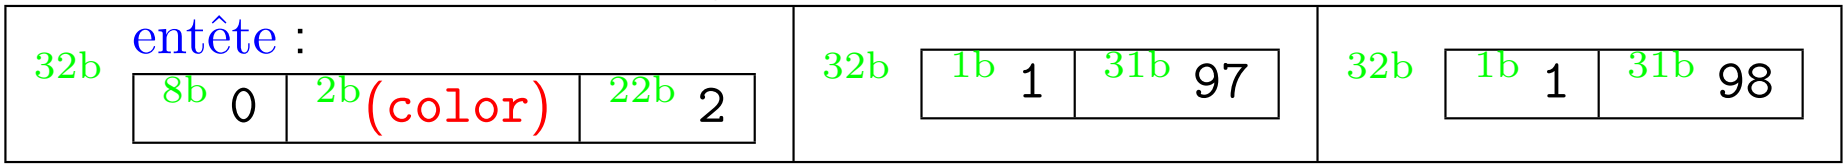

adresse dans le tas: `0x0143`

- tag : type de donnée,
  ex. string $\mapsto$ 252, float $\mapsto$ 253, fonction $\mapsto$ 247, n-uplet, enregistrements et tableau $\mapsto$ 0, types somme $\mapsto$ 0-245
- color : pour le ramasse miettes
- size : nombre cases bloc en plus de l'entête (valeurs à l'intérieur de la donnée structurée)

et un pointeur (adresse) vers la premier case de ce bloc :

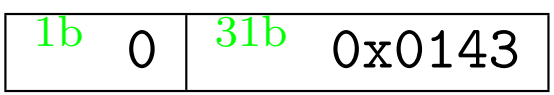

Données structurées = bloc + pointeur

Par example, la donnée `('a', 'b')` est représenté par:

Un bloc de trois cases contiguës dans le tas:

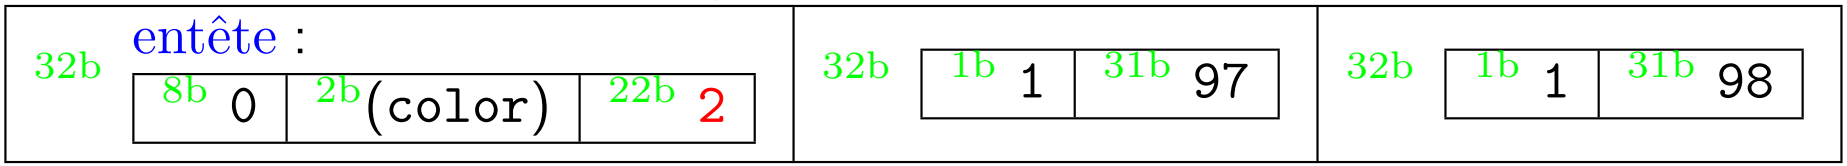

adresse dans le tas: `0x0143`

- tag : type de donnée,
  ex. string $\mapsto$ 252, float $\mapsto$ 253, fonction $\mapsto$ 247, n-uplet,
  enregistrements et tableau $\mapsto$ 0, types somme $\mapsto$ 0-245
- color : pour le ramasse miettes
- size : nombre cases bloc en plus de l'entête (valeurs à l'intérieur de la donnée structurée)

et un pointeur (adresse) vers la premier case de ce bloc :

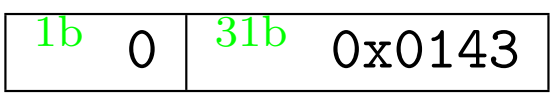

Données structurées = bloc + pointeur (II)

La donnée `(3, ('a', 'b'), false)` est représentée par:

Un pointeur:

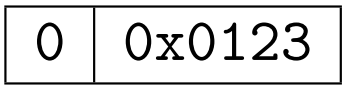

vers le bloc:

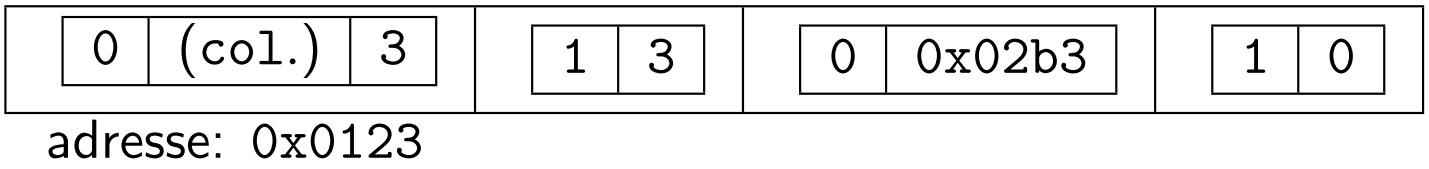

qui contient un autre pointeur vers le bloc:

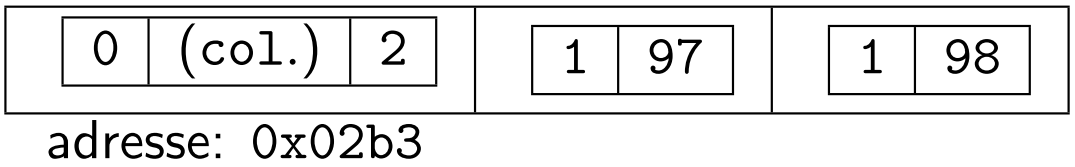

Données structurées = bloc + pointeur (III)

Avec `ocaml -dinstr` :

```
[tag:  data1 data2 data3 ....]
```

Donc

- `('a','b')`

```
[0:  'a' 'b']
```

- `(3, (25, 67))`

```
[0:  3 [0:  25 67]]
```

- `('a', 10, (3, 'b'), 0)`

```
[0:  'a' 10 [0:  3 'b'] 0]
```

Types sommes: un tag par constructeur

```
type t = A | B of int | C | D | E of t
         0   0          1   2   1
```

`A`, `C` et `D`: valeurs immédiates; `B` et `E`: pointeurs.

La valeur `D` de type `t` est codée par le mot:

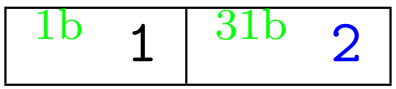

(une valeur immédiate)

Types sommes: un tag par constructeur

```
type t = A | B of int | C | D | E of t
         0   0          1   2   1
```

`A`, `C` et `D`: valeurs immédiates; `B` et `E`: pointeurs.

La valeur `A` de type `t` est codée par le mot:

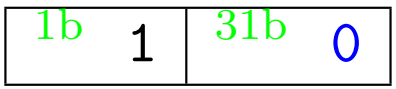

(une valeur immédiate)

Types sommes: un tag par constructeur

```
type t = A | B of int | C | D | E of t
         0   0          1   2   1
```

`A`, `C` et `D`: valeurs immédiates; `B` et `E`: pointeurs.

La valeur `B 53` de type `t` est codée par un pointeur:

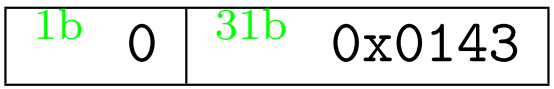

vers un bloc du tas:

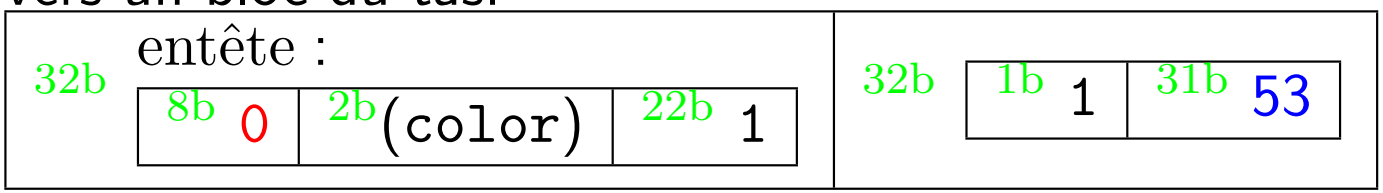

Types sommes: un tag par constructeur

```
type t = A | B of int | C | D | E of t
         0   0          1   2   1
```

`A`, `C` et `D`: valeurs immédiates; `B` et `E`: pointeurs.

La valeur `E (B 53)` de type `t` est codée par un pointeur:

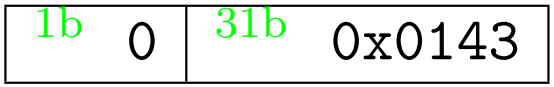

vers un bloc du tas:

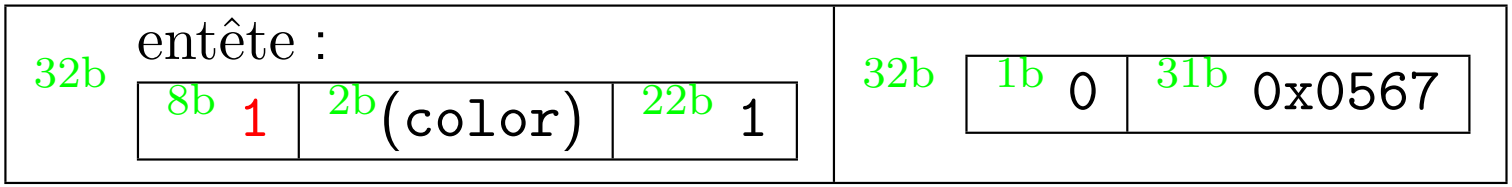

adresse 0x143

qui contient un autre pointeur vers un autre bloc du tas:

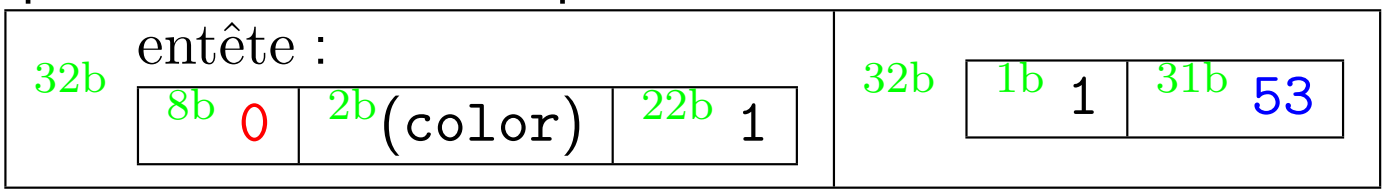

adresse 0x0567

Types sommes: un tag par constructeur

```
type t = A | B of int | C | D | E of t
         0   0          1   2   1
```

A, C et D: valeurs immédiates; B et E: pointeurs.

avec `ocamlc -dinstr`:

—	`D`	2a
—	`A`	0a
—	`B 53`	[0: 53]
—	`E (B 53)`	[1: [0: 53]]
—	`E D`	[1: 2a]

Le a en vert est une indication qu'il s'agit d'un constructeur — utile par exemple pour le ramasse-miettes.

Ocamlrun: manipulation des blocs

`makeblock n k` alloue un bloc de taille `n` et de tag `k` dans le tas et y copie les `n` éléments de `accu` et du sommet de la pile `S`; met dans `accu` un pointeur vers ce bloc.

`getfield n` `accu` doit pointer vers un bloc; la `n`-ième donnée de ce bloc est mis dans `accu`

`setfield n` Le sommet de `S` est mis comme `n`-ième donnée du bloc qui est pointé par `accu`

+ des variantes

Exemple

let x = 2 **in** (x,x+1)

donne

```
const 2
push
acc 0
offsetint 1
push
acc 1
makeblock 2, 0
return 2
```

Exemple

let x = (3,4,5) **in** **let** (y1,y2,y3) = x **in** y2

donne

```
const [0: 3 4 5]
push
acc 0
getfield 1
push
acc 0
return 3
```

Exemple

match [1;2;3] **with** [] −> 0 | x::_ −> x

donne

```
        const [0: 1 [0: 2 [0: 3 0a]]]
        push
        acc 0
        branchifnot L1
        acc 0
        getfield 0
        push
        acc 0
        return 3
L1:     const 0
        return 2
```

Ocamlrun: jeu d'instructions

Il y a presque 150 instructions,

- la plus part sont des variants similaires
- la description complète se trouve sur:

  `http://cadmium.x9c.fr/distrib/caml-instructions.pdf`

On va les regrouper en 3 parties

1. le fragment commun à Myrthe
   (gestion de la pile, arithmétique, branchement);
2. la représentation des données structurées;
3. la manipulation des fonctions.