
De Coq à ML : l'extraction de programmes

Pierre Letouzey

Equipe πr^2 (PPS, Paris 7 / INRIA)

Coq 8.3 : avis aux courageux ...

Meme s'il n'y a pas encore d'annonce officielle ...

Le processus menant à Coq 8.3 est en route !

(une branche svn existe :-)

Durant cette phase de debug, tout retour d'experience est le bienvenu

Plan

I. Introduction à l'extraction en **Coq**

1. Qu'est-ce que l'extraction ?
2. Un exemple : la division euclidienne
3. Difficultés

II. Un peu de théorie ...

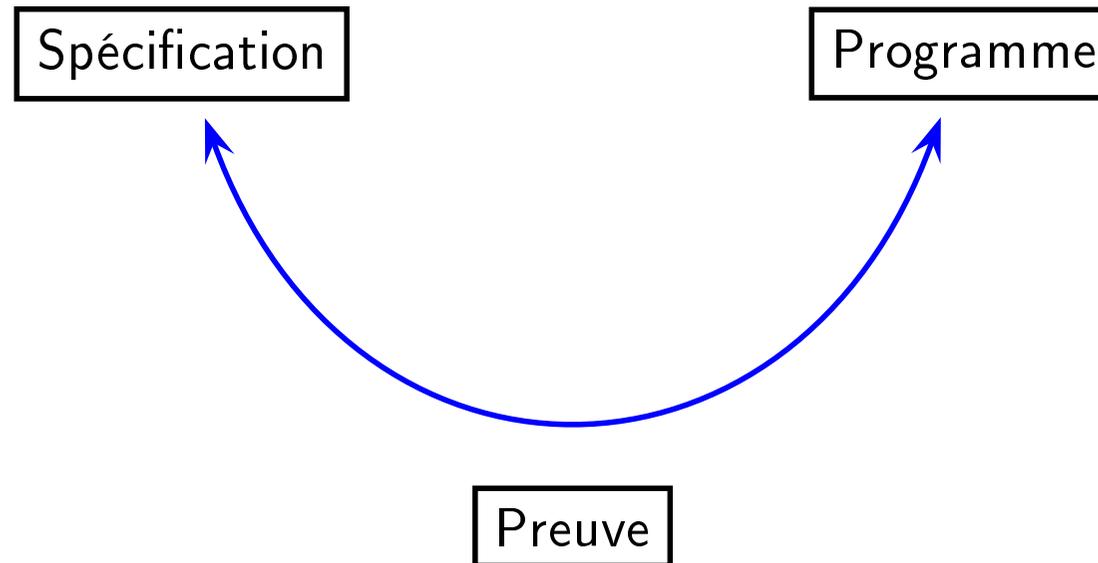
1. Définition formelle
2. Preuves de correction
3. Typage des termes extraits
4. Modules

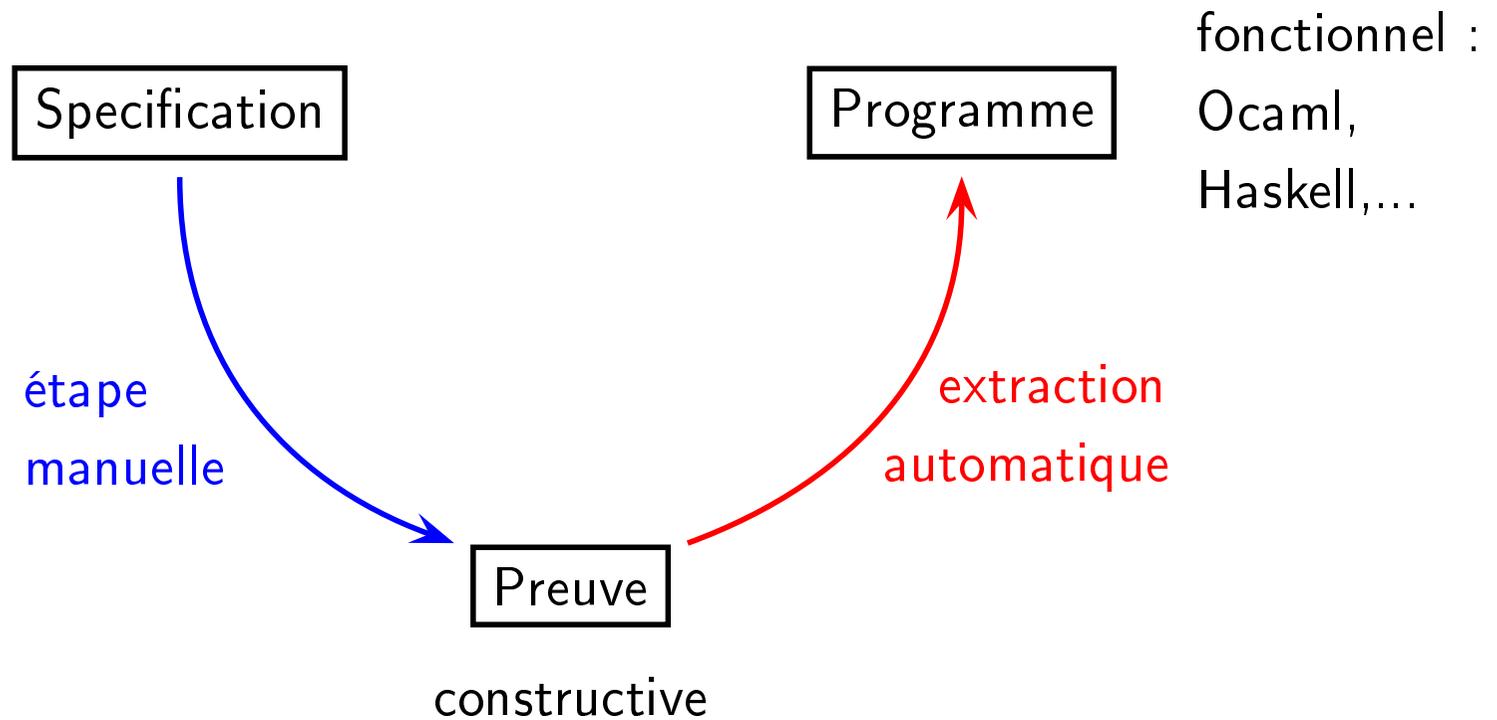
III. Études de cas

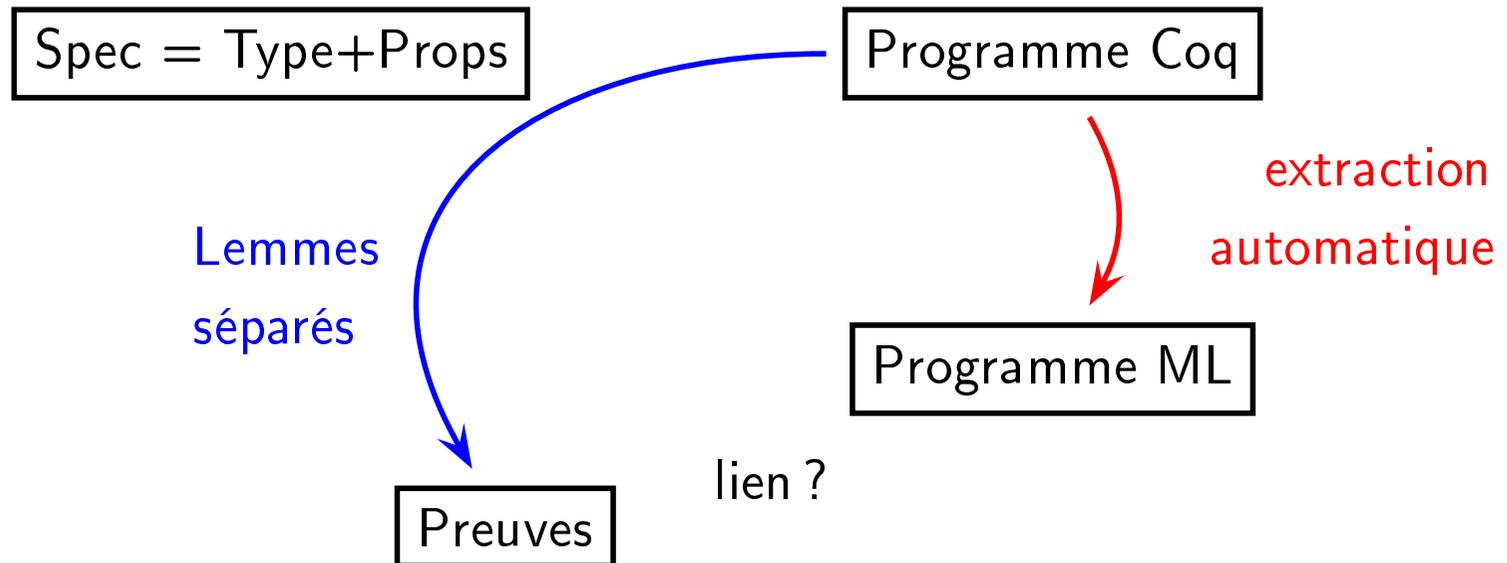
A priori demain...

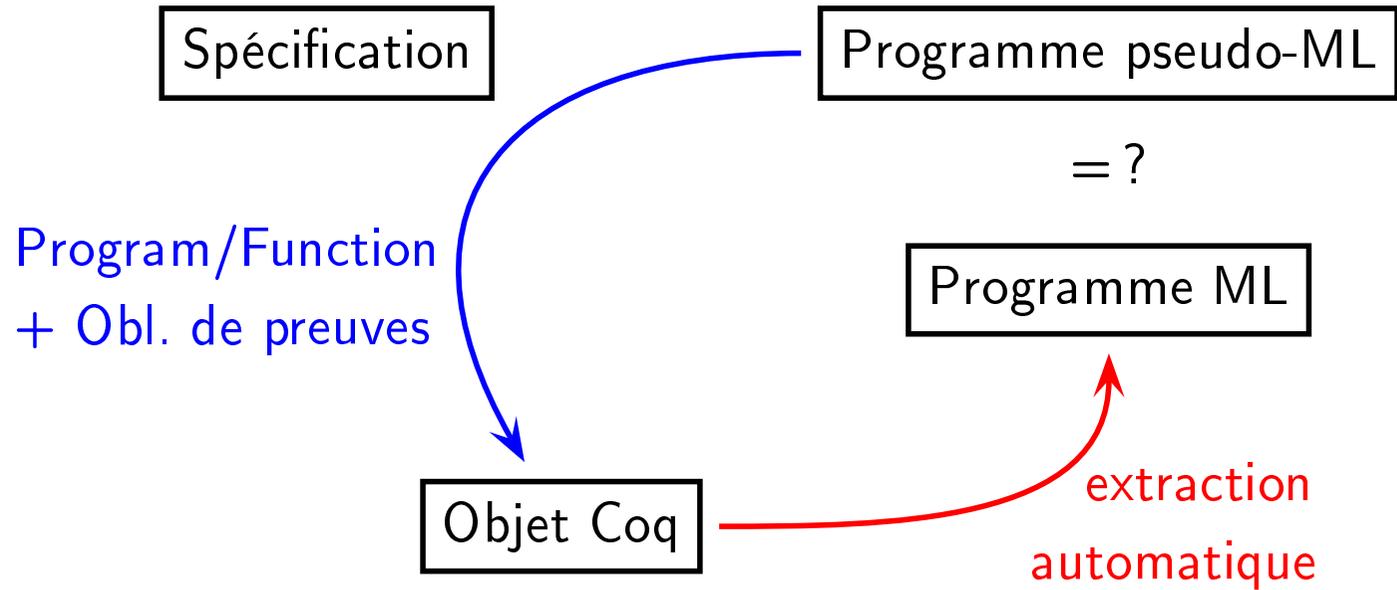
I

Introduction à l'extraction en Coq









- PX (Hayashi, 1988)
- Nuprl (Constable & alii, 1985)
- Minlog (Schwichtenberg & alii, 1990)
- Isabelle (Berghofer, 2000)
- Phox (Raffalli, 2001 ?)
- Coq (Paulin & Werner, 1989)
- Coq (Letouzey, 2000-2004)
- Coq, extraction classique (Miquel, 2009)
- ...

- **Spécification :**

⇒ Via son type

$$\text{div} : \text{nat} \rightarrow \text{nat} \rightarrow \text{nat}$$

⇒ Via une assertion : si $\text{div } a \ b = q$, alors :

$$q * b \leq a < (q+1) * b$$

- Spécification :

⇒ Via son type dépendant

$$\forall a:\text{nat}, \forall b:\text{nat}, b \neq 0 \rightarrow \exists q:\text{nat}, q*b \leq a < (q+1)*b$$

⇒ Véritable notation Coq :

$$\forall a:\text{nat}, \forall b:\text{nat}, b \neq 0 \rightarrow \{ q:\text{nat} \mid q*b \leq a < (q+1)*b \}$$

- Preuve :

$$\forall a:\text{nat}, \forall b:\text{nat}, b \neq 0 \rightarrow \{ q:\text{nat} \mid q*b \leq a < (q+1)*b \}$$

Un script Coq de 10 lignes ...

... qui engendre un objet interne de 400 lignes

- Programme :

```
let rec div a b =  
  match le_lt_dec b a with  
  | true  → S (div (minus a b) b)  
  | false → 0
```

On retrouve le type $\text{nat} \rightarrow \text{nat} \rightarrow \text{nat}$

1. Fournir du code fiable :
 - Obtenir de bonnes propriétés de correction
2. Fournir du code rapide et concis :
 - Identifier les parties utiles (calculatoires)
 - Supprimer les parties superflues (logiques)
3. Fournir du code facilement (ré-)utilisable :
 - Acceptation par les compilateurs usuels \Rightarrow `typage`
 - Intégration dans des développements plus larges \Rightarrow `interface`

- [Paulin](#) / [Werner](#) (1989) :
 - D'abord de CC vers F_ω , étendu ensuite aux inductifs
 - Distinction Prop/Set
 - Techniques à base de réalisabilité
- [Berardi](#) / [Boerio](#) / [Prost](#) (1996) :
 - Analyse de code-mort
 - Le code inutile est remplacé par une constante dédiée
 - Techniques de simulation
- [Pottier](#) (2000) : Encapsulation du λ -calcul pur dans Ocaml

$$\forall a:\text{nat}, \forall b:\text{nat}, b \neq 0 \rightarrow \{ q:\text{nat} \mid q*b \leq a < (q+1)*b \}$$

La séparation **calculatoire/logique** est assurée par le typage :

- nat est un type calculatoire, car $\text{nat} : \text{Set}$

`Inductive nat : Set := 0 : nat | S : nat → nat`

- $b=0$ est une proposition logique, car $b=0 : \text{Prop}$

- la séparation se propage aux cas non-primitifs.

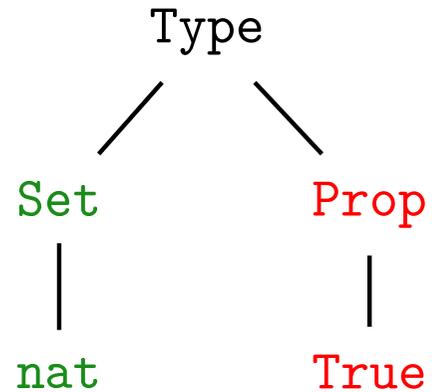
$b \neq 0$ est en fait $b=0 \rightarrow \text{False}$, de type Prop

- certaines constructions combinent **calculatoire/logique** :

$\{ q:\text{nat} \mid q*b \leq a < (q+1)*b \}$ de type Set

- Pour tout t bien typé, $t : T : s$ avec $s = \text{Set}, \text{Prop},$ ou Type

1. Support de l'ensemble de la logique de Coq ?
 - Mélange de sortes en passant par Type
 - Elimination forte : des types dependants de valeurs
 - Prop dans les calculs : `false_rec`, `eq_rec`, `Acc_rec`
2. Typabilité en ML ?
3. Exécution correcte ?
 - Eviter les "runtime error"
 - Eviter de boucler



Un terme Coq hybride :

```
if b then 0 else True
  : if b then nat else Prop
  : Type
```

Definition `dp` : $(\forall X:\text{Set}, X \rightarrow X) \rightarrow \text{nat} * \text{bool} :=$
`fun f \Rightarrow (f nat 0, f bool true).`

Extraction naturelle : `let dp = fun f \rightarrow (f 0, f true)`

Mais ceci n'est pas typable en ML

Autre exemple :

Inductive `any` : `Set` := `Any` : $\forall A:\text{Set}, A \rightarrow \text{any}.$

Une traduction infidèle : `type 'a any = Any of 'a`

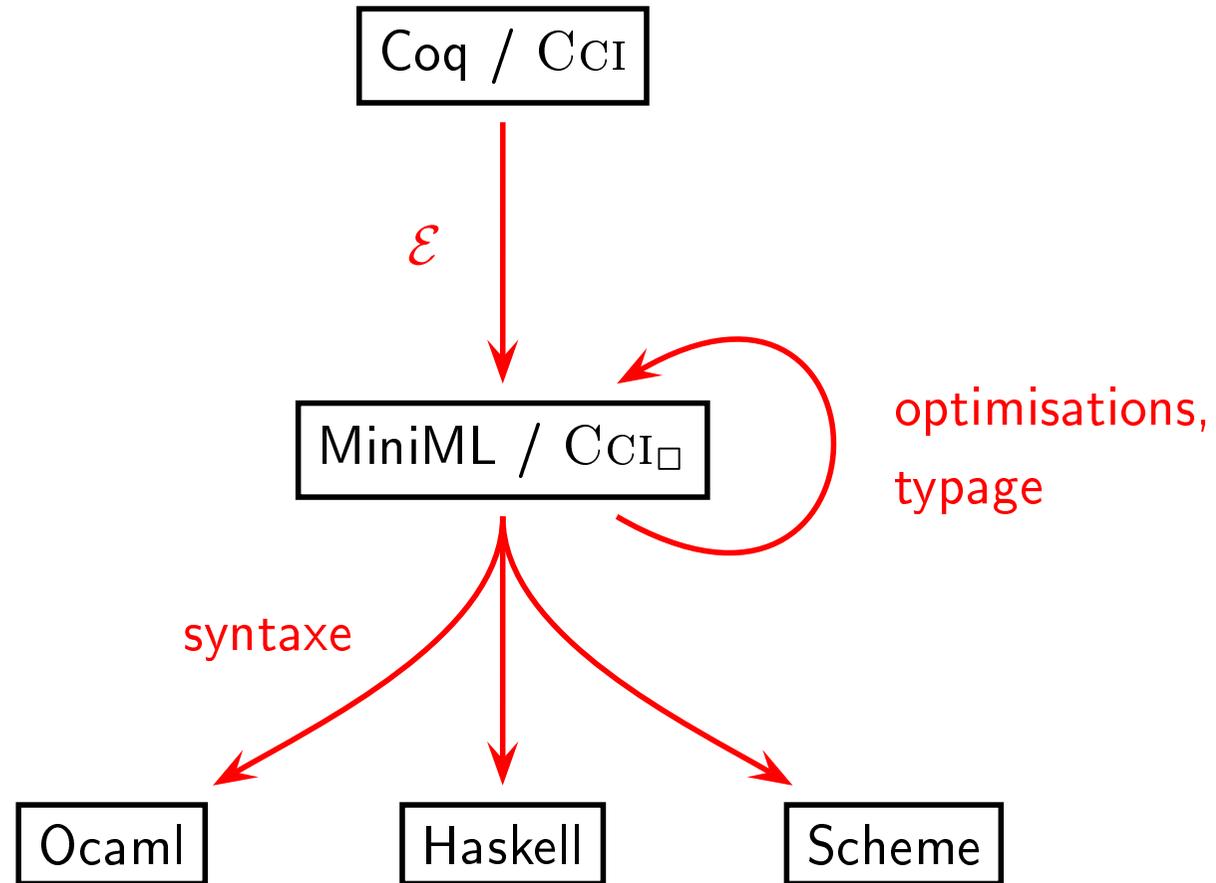
- Reprenons `div` : $\forall a:\text{nat}, \forall b:\text{nat}, b \neq 0 \rightarrow \{q:\text{nat} \mid \dots\}$
En Coq, on peut former `(div 0 0) : 0 ≠ 0 → {q:nat | ...}`
L'extraction naïve est `(div 0 0)`, qui boucle.
- Plus généralement, l'extraction naïve peut obliger à réduire des portions absurdes, inaccessibles en Coq :
⇒ levée d'exceptions, et même erreurs comme `(0 0)`.

L'ancienne théorie de C. Paulin mais ne couvrait pas ces cas, mais l'ancienne implantations si (oups).

||

Un peu de théorie...

- **Compatibilité** autant que possible : Prop/Set
- Une première passe pouvant laisser des **traces logiques** : □
- Des **optimisations** ultérieures qui en retirent beaucoup
- Un **vérificateur de types ML** embarqué dans l'extraction



Deux cas d'élagage :

- Si t admet Prop comme sorte, alors $\mathcal{E}(t) = \square$
- Si t est un schéma de types, alors $\mathcal{E}(t) = \square$

Sinon, on discrimine selon la structure de t :

- $\mathcal{E}(\text{fun } x : T \Rightarrow t) = \text{fun } x \Rightarrow \mathcal{E}(t)$
- $\mathcal{E}(u \ v) = (\mathcal{E}(u) \ \mathcal{E}(v))$
- ...

Modifications de la reduction

Un redex au niveau Coq reste-t'il un redex au niveau extrait ?

$(\text{fun } x : T \Rightarrow t) u$ devient normalement soit $(\text{fun } x \Rightarrow \mathcal{E}(t)) \mathcal{E}(u)$ soit \square

Mais apres quelques reductions, un \square peut se retrouver appliqué^a.

Au niveau théorique, une réduction $(\square x) \rightarrow \square$. Au niveau pratique, une implantation récursive de \square .

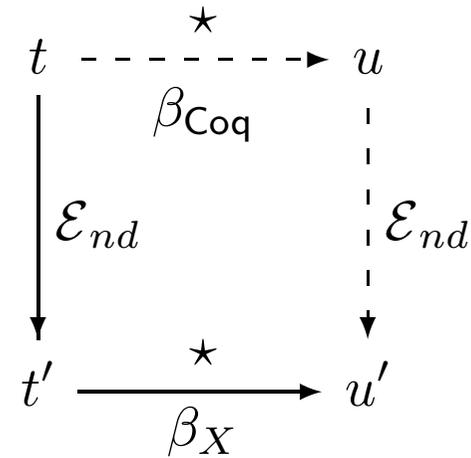
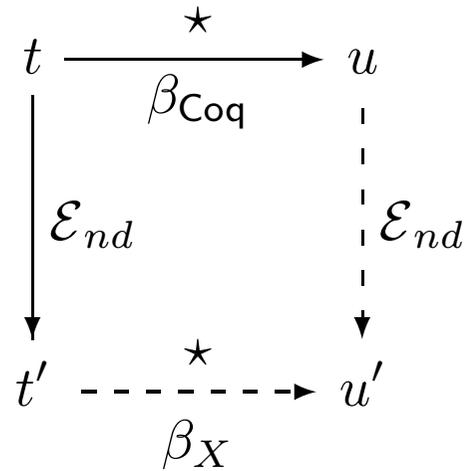
Pour les inductifs, des `match` \square `with...` peuvent exister. Deux cas seulement :

- zero branche (analyse à la `False_rec`) : pas de réduction, traduction finale en exception
- une branche (analyse à la `Eq_rec`) : on réduit directement vers cette branche.

Les points-fixes à arguments logiques (`Acc_rec`) sont aussi à traiter à part

^acf. `test_extraction.v` ligne 427

⇒ Preuve opérationnelle de bonne réduction



Condition : t clos

Deux cas pour la réduction X :

- réduction faible + stratégie paresseuse/CBN/Haskell
- réduction faible + stratégie stricte/CBV/Ocaml

En réalisabilité, usuellement ...

$$\tau(A) = \text{unit} \quad A \text{ sans contenu}$$

$$\tau(A \Rightarrow B) = \tau(A) \Rightarrow \tau(B)$$

$$\tau(\forall y:\sigma. B) = \sigma \Rightarrow \tau(B)$$

$$\tau(\exists y:\sigma. B) = \sigma \times \tau(B)$$

$$x \mathbf{r} A = A \quad A \text{ sans contenu}$$

$$f \mathbf{r} A \Rightarrow B = \forall x:\tau(A). x \mathbf{r} A \Rightarrow f(x) \mathbf{r} B$$

$$f \mathbf{r} \forall x:\sigma. B = \forall x:\sigma. f(x) \mathbf{r} B$$

$$x \mathbf{r} \exists y:\sigma. B = \text{snd}(x) \mathbf{r} B[y := \text{fst}(x)]$$

⇒ Preuve sémantique des propriétés logiques du code extrait

Par réalisabilité : si $t:T$, on prouve $\mathcal{E}(t) \Vdash T$

En fait ici : si $t:T$, on prouve $t \sim_T \mathcal{E}(t)$

Par exemple pour $T=\text{nat}$, on définit \sim_{nat} à partir de

$$0 \sim_{\text{nat}} 0_{\mathcal{E}} \text{ et } n \sim_{\text{nat}} n' \rightarrow (S n) \sim_{\text{nat}} (S_{\mathcal{E}} n')$$

Et la propriété que l'on obtient pour $\text{div} \sim \text{div}'$ est :

$$\forall a a', a \sim_{\text{nat}} a' \rightarrow$$

$$\forall b b', b \sim_{\text{nat}} b' \rightarrow$$

$$\forall h:b \neq 0, \forall h',$$

$$\exists q q', (\text{div } a \text{ b } h) = (q, -) \wedge (\text{div}' a' \text{ b}' h') = (q', -)$$

$$\wedge q \sim_{\text{nat}} q' \wedge q * b \leq a < (q+1) * b$$

- Les termes extraits vivent dans $\Lambda \neq \text{CCI}$ (ex : `Inductive Λ`)
- On ne parle pas ici de terminaison, $p \in \Lambda$ est vu modulo β
- Le système CCI exact est ingérable : besoin de marquer l'usage de la cumulativité (si $T : \text{Prop}$ alors $T^\dagger : \text{Type}$)
- Usage de paires dépendantes : $\sim_T = \llbracket T \rrbracket_2$

```
Record Set+ : Type := mk_Set
  { type_Set :> Set;
    pred_Set : type_Set →  $\Lambda$  → Prop }.
```

```
Record Prop+ : Type := mk_Prop
  { type_Prop :> Prop;
    pred_Prop : type_Prop →  $\Lambda$  → Prop := fun _ _ => True
```

- $\llbracket s \rrbracket = \text{mk_Type } s^+ \lambda_-, \lambda_-, \text{True}$
- $\llbracket t^\dagger \rrbracket = \text{Prop}^+ \text{-Type}^+ \llbracket t \rrbracket$
- $\llbracket x \rrbracket = x$
- $\llbracket t \ t' \rrbracket = \llbracket t \rrbracket \llbracket t' \rrbracket$
- $\llbracket \lambda x : T, t \rrbracket = \lambda x : \llbracket T \rrbracket_1, \llbracket t \rrbracket$
- $\llbracket \forall x : T, T' \rrbracket =$

$$\text{mk_s}$$

$$\forall x : \llbracket T \rrbracket_1, \llbracket T' \rrbracket_1$$

$$\lambda t, \lambda p, \forall x : \llbracket T \rrbracket_1, \forall x' : \Lambda, \llbracket T \rrbracket_2 \ x \ x' \rightarrow \llbracket T' \rrbracket_2 \ (t \ x) \ (p \ x')$$
- ...

Travaux de thèse de Stéphane Glondu, a la fois par bisimulation et par réalisabilité.

- Des programmes extraits parfois mal typés, mais corrects
- `Obj.magic` : contournement local du typage, non-sûr

`(Obj.magic t) : 'a`

`(Obj.magic t) \rightarrow_{β} t`

- But : en utiliser le moins possible
- But : des types proches de ceux de Coq, et prédictibles

\Rightarrow Pour tout type T de Coq, une approximation Ocaml $\widehat{\mathcal{E}}(T)$, utilisant éventuellement un type inconnu \mathbb{T}

\Rightarrow Pour $t:T$, un vérificateur de types impose $\mathcal{E}(t) : \widehat{\mathcal{E}}(T)$ en plaçant des `Obj.magic` dans $\mathcal{E}(t)$.

Algorithme de typage \mathcal{M} (Caml Light / Lee & Yi 1998) :

- Variante de \mathcal{W} , mais top-down et non bottom-up.
- Intérêt pour l'extraction : vérifie plutôt qu'infère un type.
- On commence donc avec le type espéré $\hat{\mathcal{E}}(T)$.
- Seule modification : une unification qui ne rate jamais !
Échec \Rightarrow insertion d'un `Obj.magic`.

- Des termes extraits qui typent toujours, même avec l'extraction des modules.
- Mieux, on connaît leur type à l'avance : production de fichiers interface `.mli`.
- Un critère de simplicité : pas d'`Obj.magic` s'ils sont superflus pour que le terme extrait ait le type attendu.
- Mais parfois plus d'`Obj.magic` qu'il semble nécessaire.

Coq propose un système de modules/foncteurs/signatures

Similaire au système d'Ocaml, avec en plus les aspects Coq : types dépendants, parties logiques, ...

⇒ L'extraction traduit de l'un vers l'autre

Application : la certification de bibliothèques

Un exemple significatif : FSets

III

Études de cas

À l'origine, la bibliothèque Set de Ocaml :

```
module type OrderedType = sig
  type t
  val compare : t → t → int
end

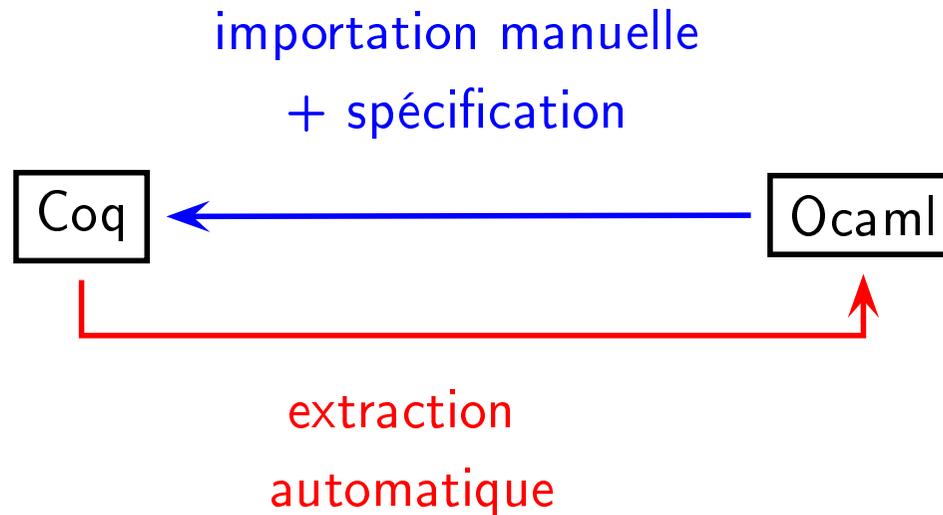
module Make (X:OrderedType) : sig

  type t
  val empty : t
  val add : X.t → t → t
  val union : t → t → t
  :
end
```

- Extraction usuelle :



- Ici, on s'appuie sur du code Ocaml existant :



```
Module Type OrderedType.  
  Parameter t : Set.  
  Parameter eq lt : t → t → Prop.  
  Parameter compare : ∀x y, {lt x y}+{eq x y}+{lt y x}.  
  Axiom eq_refl : ∀x, eq x x.  
  
  Axiom eq_sym : ∀x y, eq x y → eq y x.  
  Axiom eq_trans : ∀x y z, eq x y → eq y z → eq x z.  
  Axiom lt_trans : ∀x y z, lt x y → lt y z → lt x z.  
  Axiom lt_not_eq : ∀x y, lt x y → ¬ eq x y.  
End OrderedType.
```

```
Module Type S.  
  Declare Module E : OrderedType.  
  Definition elt := E.t.  
  Parameter t : Set.  
  :  
  (* add x s returns a set containing all elements of s,  
  plus x. If x was already in s, s is returned unchanged.*)  
  Parameter add : elt → t → t.  
  Parameter add_spec :  $\forall x y:elt, \forall s:t,$   
     $In\ y\ (add\ x\ s) \leftrightarrow E.eq\ y\ x \vee In\ y\ s.$   
  :
```

- Trois implantations certifiées :
listes triées, arbres rouges-noirs, arbres AVL
- 7000 lignes de développement Coq
- Une erreur d'équilibrage trouvée dans le code d'origine !
- 700 lignes du code extrait, très similaire à l'original, presque aussi efficace (sauf l'arithmétique sur les hauteurs)
- Validation grandeur nature du coupe modules+extraction

Compcert : un compilateur C certifié

Travail impressionnant de Xavier Leroy et alii.

Autour de 10000 lignes de code extrait.

FingerTree

Bibliothèque d'arbres par Matthieu Sozeau.

Usage intense de types dépendents.

« Tout polynôme sur \mathbb{C} non constant a au moins une racine »

Un développement impressionnant (40 000 lignes) à Nimègue

Preuve constructive \Rightarrow méthode de recherche d'une racine

Mais l'extraction n'a pas été envisagée initialement

\Rightarrow Beaucoup d'efforts pour obtenir un programme

Taille imposante \Rightarrow besoin d'une partition fine Prop/Set.

- À l'origine, tout dans Prop : 0 Ko extrait
- Puis tout dans Set : 15 Mo extrait
- Étude détaillée : 250 Ko extrait

De nombreux `Obj.magic` (presque 400)

Problèmes d'efficacité des représentations (unaires/binaires) et des algorithmes.

Dilemme au niveau de la modularité : interface riche ou non ?

- Un programme extrait de taille «raisonnable», qui compile
- La recherche de racines : inutilisable
- Des résultats intermédiaires encourageants : séries
- Encore beaucoup à explorer (ex : réduire des fractions)

Quelques perspectives

- Extraction modulaire plus maligne
- Extraction pseudo-modulaire en Haskell
- Eval extraction in ...
- Programmation défensive
- Code extrait “sur-mesure” :
 - Extract Inductive vers des types non-inductifs
 - implicites / variables n.c.
 - traduction monadique vers exn / code impératif
 - fixpoints sans compteurs
 - ...