

# Union de variants abstraits

---

Jacques Garrigue  
Nagoya University, Grad. Sch. of Mathematics  
avec Romain Bardou, E.N.S. Cachan

## Union concrète

---

```
type u = ['A of int | 'B of bool]
let show_u = function .....
val show_u : u -> unit
```

```
type v = ['C of char | 'D of string]
let show_v = function .....
val show_v : v -> unit
```

```
type t = [u | v]
type t = ['A of int | 'B of bool | 'C of char | 'D of string]
let show = function
  #u as x -> show_u x
  | #v as y -> show_v y
val show : t -> unit
```

## Union concrète

---

```
type u = ['A of int | 'B of bool]
let show_u = function .....
val show_u : u -> unit
```

```
type v = ['C of char | 'A of string]
let show_v = function .....
val show_v : v -> unit
```

```
type t = [u | v]
```

This variant type contains a constructor  
[ 'A of string ] which should be [ 'A of int ]

**On vérifie que  $u$  et  $v$  sont compatibles**

## Union abstraite

---

Que se passe-t-il dans le cas abstrait?

```
module type T =
  sig type t = private [> ] val show : t -> string end
module Mix(X : T)(Y : T) =
  struct
    type t = [X.t | Y.t]
    let show : t -> string = function
      | #X.t as e -> X.show e
      | #Y.t as e -> Y.show e
  end
```

**Comment assurer la compatibilité de X.t avec Y.t?**

## Union abstraite

---

Idée: déclarer les compatibilités en même temps que les types

```
module type T =  
  sig type t = private [> ] val show : t -> string end  
module Mix(X : T)(Y : T with type t = private [> ] ~ [X.t]) =  
  struct  
    type t = [X.t | Y.t]  
    let show : t -> string = function  
      | #X.t as e -> X.show e  
      | #Y.t as e -> Y.show e  
  end
```

Y.t et X.t compatibles

# Applications

---

## Construction modulaire de programmes

- domaine d'une interprétation abstraite
- construction d'automates finis
- factorisation de code dans des bibliothèques: GUI, etc. . .
- construction de langages (problème de l'expression. . .)

## Étendre le typage à $F_{<}$

- permet les variables (càd types abstraits) dans les bornes supérieures et inférieures

# Synopsis

---

- Unions concrètes et abstraites
- Modélisation avec compatibilités
- Vérification des compatibilités
- Union disjointe
- Union semi-disjointe
- Union avec borne supérieure
- Intégration à l'inférence de types

## Compatibilités

---

On introduit 4 types de compatibilités:

```

type t = private [ $\triangleright D$ ] ~ [ $C$ ]
 $D ::= A \text{ of } \tau \mid t$ 
 $C ::= A \text{ of } \tau$    si  $A$  présent, alors de type  $\tau$ 
                |  $t$        compatible avec  $t$ 
                |  $\neg A$      $A$  absent
                |  $\neg t$    pas d'intersection avec  $t$ 

```

Comment formaliser leur sémantique?

## Modélisation: union de fonctions

---

Une valuation assigne un type de variant à chaque déclaration de type.

$$\mathcal{V} = N \rightarrow \mathcal{L} \rightarrow T_\emptyset$$

$N = \{t_1, \dots\}$ : noms de types

$\mathcal{L} = \{A, B, \dots\}$ : noms de labels

$T = \{\tau_1, \dots\}$ : types

$T_\emptyset = T \cup \{\emptyset\}$ :  $\emptyset$  exprime l'absence d'un label

Deux types  $t_1$  et  $t_2$  sont compatibles pour une valuation  $v \in \mathcal{V}$  si l'union  $v(t_1) \cup v(t_2)$  est cohérente.

$$\forall l \in \mathcal{L} \ v(t_1)(l) = \emptyset \vee v(t_2)(l) = \emptyset \vee v(t_1)(l) = v(t_2)(l)$$

Un modèle  $W$  est un ensemble de valuations.  $t_1$  et  $t_2$  sont compatibles pour  $W$ , si ils sont compatibles pour toutes les valuations de  $W$ .

## Modélisation des définitions

---

On étend les valuations aux types et compatibilités.

$$\begin{aligned}
 \tilde{v}(t) &= v(t) \\
 \tilde{v}(l \text{ of } \tau) &= \{l \mapsto \tau\} \\
 \tilde{v}(\neg l) &= \{l \mapsto \Omega\} \\
 \tilde{v}(\neg t) &= \{l \mapsto \Omega \mid v(t)(l) \neq \emptyset\}
 \end{aligned}$$

Partant de  $W_0 = \mathcal{V}$ , on raffine le modèle incrémentalement en ajustant la définition de chaque type. Pour ajouter une définition  $\delta$  au modèle  $W$ , on applique la fonction  $V_W(\delta)$ .

Pour les types fermés, il suffit de ne garder que les valuations où la définition est la bonne.

$$V_W(\text{type } t = [D]) = \{v \in W \mid v(t) = \bigcup_{D \in \mathcal{D}} \tilde{v}(D)\}$$

## Modélisation des définitions (2)

---

Pour les types privés

$$\delta = (\text{type } t = \text{private}[\triangleright \mathcal{D}] \sim [\mathcal{C}])$$

on vérifie d'abord la définition,

$$V_W^0(\delta) = \{v \in W \mid v(t) \supseteq \bigcup_{D \in \mathcal{D}} \tilde{v}(D)\}$$

puis les compatibilités.

$$V_W(\delta) = \{v \in V_W^0(\delta) \mid \forall C \in \mathcal{C}, v(t) \cup \tilde{v}(C) \text{ is coherent}\}$$

## Validité des définitions

---

Une définition  $\delta$  est **valide** dans  $W$  si

$$\forall v \in W, \forall (D, C) \in \mathcal{D} \times (\mathcal{D} \cup \mathcal{C}), \tilde{v}(D) \cup \tilde{v}(C) \text{ is coherent}$$

**Thm 1** *Si  $\delta$  est valide dans  $W$ , alors  $V_W(\delta)$  est **conservatif**.*

$$\forall v \in W, \exists v' \in V_W(\delta), \forall t' \neq t, v'(t') = v(t')$$

**Thm 2** *Si  $V_W(\delta)$  est conservatif, et  $\delta$  ne fait référence qu'à des types définis, alors  $\delta$  est valide dans  $W$ .*

# Axiomatisation

---

Les information sur les types privés sont données par un environnement  $\Delta$ .

$$\begin{aligned} D & ::= l \text{ of } \tau \mid t \\ R & ::= D \mid ?D \mid \neg D \\ \Delta & ::= l \mapsto R^*, \dots \end{aligned}$$

$$\begin{array}{ll} D \in \Delta(t) & D \text{ inclus dans } t \\ ?D \in \Delta(t) & D \text{ compatible avec } t \\ \neg D \in \Delta(t) & D \text{ disjoint de } t \end{array}$$

Deux jugements:

$$\begin{array}{ll} \Delta \vdash R \in t & t \text{ hérite } R \\ \Delta \vdash D \odot D' & D \text{ compatible avec } D' \\ \Delta \vdash \neg D \odot D' & D \text{ disjoint de } D' \end{array}$$

## Axiomatisation (2)

---

$$\frac{R \in \Delta(t)}{\Delta \vdash R \in t} \text{In1} \quad \frac{t' \in \Delta(t) \quad \Delta \vdash D \in t'}{\Delta \vdash D \in t} \text{In2}$$

$$\frac{?t' \in \Delta(t) \quad \Delta \vdash D \in t'}{\Delta \vdash ?D \in t} \text{In3} \quad \frac{\neg t' \in \Delta(t) \quad \Delta \vdash D \in t'}{\Delta \vdash \neg D \in t} \text{In4}$$

$$\frac{\Delta \vdash C \in t}{\Delta \vdash C \odot t} \text{E1} \quad \frac{\Delta \vdash ?D \in t}{\Delta \vdash D \odot t} \text{E2} \quad \frac{\Delta \vdash \neg D \in t}{\Delta \vdash D \odot t} \text{E3}$$

$$\frac{\Delta \vdash ?l \text{ of } \tau_1 \in t \quad \Delta \vdash ?l \text{ of } \tau_2 \in t \quad \tau_1 \neq \tau_2}{\Delta \vdash l \text{ of } \tau \odot t} \text{LT}$$

$$\frac{l \neq l' \text{ or } \tau = \tau'}{\Delta \vdash l \text{ of } \tau \odot l' \text{ of } \tau'} \text{LL} \quad \frac{\Delta \vdash D' \odot D}{\Delta \vdash D \odot D'} \text{Sym} \quad \frac{\Delta \vdash \neg D \odot D'}{\Delta \vdash \neg D' \odot D} \text{Any}$$

## Complétude de l'axiomatisation

---

**Thm 3** *L'axiomatisation de la compatibilité est correcte et complète par rapport au modèle décrit précédemment.*

Ce résultat est important, car trouver les bonnes règles n'est pas facile. Par exemple, la règle suivant est fausse:

$$\frac{t' \in \Delta(t) \quad \Delta \vdash ?D \in t'}{\Delta \vdash ?D \in t} \text{In2}$$

N.B. La preuve a été faite pour une version ne contenant pas la négation de types ( $\neg t$ ), seulement d'étiquette ( $\neg l$ ).

## “La” solution ?

---

- Compatibilités très expressives
- Sémantique bien définie

Mais

- Axiomisation compliquée (inévitable?)
- En présence de foncteurs, LT3 n'est pas correcte.
  - sans elle, on perd la complétude
  - difficile de la récupérer
- La vérification de compatibilités pendant l'inférence n'est pas principale.

## Contre-exemple pour LT3

---

```
module M : sig
  type t
  type u = [> ] ~ ['L of int | 'L of t]
  val v : [> u]
end = struct
  type t = int
  type u = ['L of t]
  let v = 'L 1
end

let l : [u | 'L of bool] list = ['L true; v]
```

## Restreindre LT3?

---

Le modèle choisi n'est pas assez précis. Ne pourrait-on pas avoir une définition précise des cas où deux types ne peuvent pas être rendus compatibles?

### Difficile

- Nécessite une analyse globale pour les types abstraits: il ne suffit pas de s'attaquer aux paramètres de foncteurs.
- Ceux-ci sont utilisés pour modéliser les types de base: comment prouver `int ≠ bool`?
- Même sans ça, implémentation complexe: besoin d'une nouvelle infrastructure pour traiter l'égalité potentielle.

## Perte de principalit 

---

```
module M : sig
  type t
  type u = [> ] ~ ['L of int | 'L of t]
  val v : [> u]
end = struct
  type t = int
  type u = ['L of t]
  let v = 'L 1
end

let f x = ['L x; v]
```

Quel type pour x? Aussi bien `int` que `t` sont valides.

## Solution radicale

---

Exiger que les compatibilités soient compatibles entre elles.

$$\delta = (\text{type } t = \text{private}[\triangleright \mathcal{D}] \sim [\mathcal{C}])$$

La validité originelle était

$$\forall C \in \mathcal{D} \cup \mathcal{C}, \forall D \in \mathcal{D}, \Delta \vdash C \odot D$$

Il faut ajouter

$$\forall D, D' \in \mathcal{C}, \Delta \vdash D \odot D' \vee \exists \neg D'' \in \mathcal{C}, (\Delta \vdash \neg D'' \odot D \vee \Delta \vdash \neg D'' \odot D')$$

Pas d'affaiblissement sensible, mais moins intuitif.

## Alternatives

---

- Union disjointe  
équivalent des rangées à la Rémy
- Union semi-disjointe  
similaire, mais mieux adaptée aux types privés
- Union avec borne supérieure  
régle la question des compatibilités à l'avance

## Union disjointe

---

On ne conserve que les compatibilités  $\neg l$  et  $\neg t$ .

Modèle et axiomatisation simplifiés.

Difficulté pour exprimer des cas où les types ont une intersection.

```
module F(I:sig type t = [> ] type t1 = [> ]~[t]
           type t2 = [> ]~[t;t1] end)
  (X:sig type t = [I.t|I.t1] ... end)
  (Y:sig type t = [I.t|I.t2] ... end) =
struct
  type t = [X.t | Y.t]
  let show : t -> string =
    function #X.t as x -> X.show x | #Y.t as y -> Y.show y
end
```

## Union semi-disjointe

---

Les compatibilités sont traitées comme disjointes pour leurs parties abstraites.

On peut donc écrire:

```
module F(I:sig type t = [> ] end)(X:sig type t = [> I.t] ... end)
  (Y:sig type t = [> I.t] ~ [X.t] ... end) =
struct
  type t = [X.t | Y.t]
  let show : t -> string =
    function #X.t as x -> X.show x | #Y.t as y -> Y.show y
end
```

## Union semi-disjointe (2)

---

Intuition: on interprète

```
type t = [> t0 ] ~ [u1; u2]
```

comme

```
type t_row = [> ] ~ [~u1; ~u2; ~t0]  
type t = [t0 | t_row] ~ [u1; u2]
```

Les compatibilités sur `t` sont vérifiées lors de la définition, donc elles ne sont pas nécessaires après. Par conséquent il ne reste que les compatibilités disjointes sur `t_row`.

## Union semi-disjointe (3)

---

L'axiomatisation est très simple:

$$\frac{l \in \Delta(t)}{\Delta \vdash l \text{ of } \tau \odot t} \text{LT}$$

$$\frac{t = t' \text{ or } t' \in \Delta(t)}{\Delta \vdash t' \odot t} \text{TT}$$

$$\frac{l \neq l' \text{ or } \tau = \tau'}{\Delta \vdash l \text{ of } \tau \odot l' \text{ of } \tau'} \text{LL}$$

$$\frac{\Delta \vdash D' \odot D}{\Delta \vdash D \odot D'} \text{Sym}$$

La sémantique est plus subtile:

$$W \models D_1 \oplus D_2 \Leftrightarrow \exists \mathcal{D}, \forall v \in W, \left\{ \begin{array}{l} \tilde{v}(D_1) \cup \tilde{v}(D_2) \text{ coherent} \\ \bigcup_{D \in \mathcal{D}} \tilde{v}(D) = \tilde{v}(D_1) \cap \tilde{v}(D_2) \end{array} \right.$$

Càd  $\mathcal{D}$  est une description syntaxique de l'intersection de  $D_1$  et  $D_2$ .

## Union semi-disjointe

---

- Simple à axiomatiser et implémenter.  
(branche varunion du CVS ocaml)
- Intuitivement prôche des rangées à la Rémy,  
tout en étant adaptée aux rangées privées.

Mais

- Sémantique un peu subtile.
- Il faut déclarer explicitement les intersections.

## Union avec borne supérieure

---

On introduit des sous-types abstraits de types abstraits:

```
module F(U:sig type t = [> ] end)(X:sig type t = [< U.t] ... end)
  (Y:sig type t = [< U.t] ... end) =
  struct
    type t = [X.t | Y.t]
    let show : t -> string =
      function #X.t as x -> X.show x | #Y.t as y -> Y.show y
  end
```

- Plus besoin de compatibilités: il faut juste vérifier l'existence d'un supertype commun
- Il est facile de construire ce supertype (l'union)

## Union avec borne supérieure (2)

---

Difficulté: quel type donner aux unions, et comment garder la principalité de l'inférence?

```
type t = private [> 'A of int]
type u = private [< t]
let f = function #u -> true | 'A x -> x
val f : [< 'A of int & bool | u] -> int
```

Comment savoir que `u` non plus n'est pas utilisable ici (puisque `u` inclus potentiellement `'A`)?

Le problème est que `[> u]` ne s'expande pas en `[> 'A of int | t]` (on ne sait pas si `'A` est là).

## Contraintes locales

---

En OCaml, les variants polymorphes sont typés par des contraintes qui n'engendrent pas de dépendences.

Idée: un type de variant est décrit comme la paire d'une **contrainte structurelle**  $C$  et d'une **relation de typage**  $R$ :

$$k = (C, R)$$

- $C$  décrit quels constructeurs peuvent ou doivent être présents
- $R$  associe à chaque constructeur le type de son argument

$C$  agit sur  $R$  par des contraintes de propagation, qui peuvent obliger tous les types associés à  $l$  dans  $R$  à être identiques.

$$(C \vdash \text{unique}(l)) \wedge (l \mapsto \tau \in R) \wedge (l \mapsto \tau' \in R) \Rightarrow \tau = \tau'$$

## Typage des variants polymorphes

---

Dans le cas des variants polymorphe usuels, la contrainte est représentée par une paire d'ensembles:

$$C = (L, U)$$

- $L$  ensemble fini de constructeurs obligatoirement présents.
- $U$  ensemble de constructeur potentiellement présents.
- $C$  est valide ssi  $L \subset U$ .
- $C \vdash \text{unique}(l)$  ssi  $l \in L$ .

## Typage des variants polymorphes (2)

---

```
[‘A 1; ‘B true] : [> ‘A of int | ‘B of bool] list
```

$$\alpha :: (\{A, B\}, \mathcal{L}, \{A \mapsto int, B \mapsto bool\}) \triangleright \alpha \text{ list}$$

```
let f = function ‘A x -> x = 0 | ‘B y -> y
val f : [< ‘A of int | ‘B of bool] -> bool
```

$$\alpha :: (\emptyset, \{A, B\}, \{A \mapsto int, B \mapsto bool\}) \triangleright \alpha \rightarrow \text{bool}$$

# Types avec borne inférieure abstraite

---

- Les types abstraits sont traités comme des constructeurs
- Les compatibilités sont vérifiées par l'unification

```

type t = private [> 'A of int] ~ ['B of bool; ~'C]
type 'a u = private [> 'B of bool; 'C of 'a] ~ [t]
val v : [> t | char u]

```

$$\alpha_t :: (\{A, t\}, \mathcal{L}, 1, \{A \mapsto int, B \mapsto bool, t \mapsto []\})$$

$$\alpha_u :: (\{B, C, u\}, \mathcal{L}, 1, \{B \mapsto bool, C \mapsto \alpha, t \mapsto [], A \mapsto int, u \mapsto [\alpha]\})$$

$$\alpha_v :: (\{A, B, C, t, u\}, \mathcal{L}, 0, \{A \mapsto int, B \mapsto bool, C \mapsto char, t \mapsto [], u \mapsto [char]\})$$

## Types avec borne inférieure abstraite (2)

---

Les compatibilités des types abstraits sont vérifiées via la validité de la contrainte:

$C = (L, U, p)$  est valide si

- $L \subset U$
- $\forall t, t \in U \Rightarrow t \in L$
- $\forall t, t' \in L, \Delta \vdash t \odot t'$
- $\forall l, t \in L, \Delta \vdash l \odot t$

Dans la relation de compatibilité ci-dessus on peut ignorer les paramètres de types, qui sont traités par  $R$ .

## Types avec borne supérieure abstraite

---

La même approche est applicable, mais cette fois-ci il faut étendre la définition de **unique**.

On introduit d'abord présence potentielle d'un constructeur dans un type abstrait.

$$\Delta \vdash l \in_? t \quad l \text{ un constructeur ou un type abstrait}$$

Elle correspond au cas où  $l \in U$  pour  $\alpha_t :: (L, U, \dots)$ .

On peut alors ajouter

$$(C \vdash \text{unique}(t)) \wedge (\Delta \vdash l \in_? t) \Rightarrow (C \vdash \text{unique}(l))$$

Cela permet de déclencher l'unification sur un constructeur dès qu'un type le contenant potentiellement est présent.

# Compilation

---

```
module type T = sig type t = private [> ] val show : t -> string end
module Mix(X : T)(Y : T) = struct
  type t = [X.t | Y.t]
  let show : t -> string = function
    | #X.t as e -> X.show e
    | #Y.t as e -> Y.show e
end
```

On a besoin d'un moyen de savoir si une valeur fait partie de `X.t`.

Idée: on ajoute automatiquement `val mem_#t : [> t] -> bool` à la signature `T`, et on l'utilise pour le filtrage.

La fonction correspondante est automatiquement générée lorsque l'on coerce un module vers cette signature, par exemple lors d'une application de foncteur.

## Conclusion

---

L'union de variants abstraits est utile, mais elle introduit des problèmes complexes.

Elle est aussi intéressante d'un point de vue théorique: elle permet d'obtenir l'expressivité de  $F_{<}$ .

Chaque solution a ses points forts, et il est possible de combiner plusieurs solutions pour améliorer l'expressivité.

Quel est le meilleur choix du point de vue d'un langage de programmation?