

# Typage en FUN.

## 1 Définition du système de types.

L'ensemble  $\text{Typ}$  des types, notés  $\tau, \tau_1, \tau', \dots$ , est défini par la grammaire suivante :

$$\tau ::= \text{int} \mid \tau_1 \rightarrow \tau_2.$$

**Note 1.** Attention ! Le type  $\tau_1 \rightarrow \tau_2 \rightarrow \tau_3$  n'est pas égal au type  $(\tau_1 \rightarrow \tau_2) \rightarrow \tau_3$ . En effet, dans le premier cas, c'est une fonction qui renvoie une fonction ; et, dans le second cas, c'est une fonction qui prend une fonction.

**Définition 1.** Un *environnement de typage*, noté  $\Gamma, \Gamma_1, \Gamma', \dots$ , est un dictionnaire sur  $(\mathcal{V}, \text{Typ})$ , où  $\text{Typ}$  est l'ensemble des types.

Une *hypothèse de typage*, notée  $x : \tau$ , est un couple  $(x, \tau)$ .

On note  $\Gamma, x : \tau$  l'extension de  $\Gamma$  avec l'hypothèse de typage  $x : \tau$  qui n'est définie que lorsque  $x \notin \text{dom } \Gamma$ .<sup>1</sup>

**Remarque 1.** On peut voir/implémenter  $\Gamma$  comme des listes finies de couples  $(x, \tau)$ .

**Définition 2.** La *relation de typage*, notée  $\Gamma \vdash e : \tau$  (« sous les hypothèses  $\Gamma$ , l'expression  $e$  a le type  $\tau$  ») est définie par les règles d'inférences suivantes.

---

1. La définition de  $\Gamma, x : \tau$  est « comme on le pense ».

$$\frac{}{\Gamma \vdash k : \text{int}} \mathcal{T}_k \quad \frac{\Gamma(x) = \tau}{\Gamma \vdash x : \tau} \mathcal{T}_v \quad \frac{\Gamma, x : \tau_1 \vdash e_2}{\Gamma \vdash \text{fun } x \rightarrow e : \tau_1 \rightarrow \tau_2} \mathcal{T}_f$$

$$\frac{\Gamma \vdash e_1 : \text{int} \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1 + e_2 : \text{int}} \mathcal{T}_p \quad \frac{\Gamma \vdash e : \tau_1 \rightarrow \tau_2 \quad \Gamma \vdash e' : \tau_1}{\Gamma \vdash e \ e' : \tau_2} \mathcal{T}_a$$

**Remarque 2.** Pour l’instant, on parle uniquement d’expressions et pas du tout de valeurs ou de sémantique opérationnelle.

- Remarque 3.**
1. On dit que  $e$  est *typable* s’il existe  $\Gamma$  et  $\tau$  tel que  $\Gamma \vdash e : \tau$ .
  2. Il y a une règle de typage par construction du langage des expressions.

**Exemple 1.**

1. L’expression  $\text{fun } x \rightarrow x$  est particulière : on peut la typer avec  $\tau \rightarrow \tau$  quel que soit  $\tau$ . Par exemple,

$$\frac{\frac{}{x : \text{int} \vdash x : \text{int}} \mathcal{T}_v}{\emptyset \vdash \text{fun } x \rightarrow x : \text{int} \rightarrow \text{int}} \mathcal{T}_f$$

On aurait pu faire de même avec le type  $(\text{int} \rightarrow \text{int}) \rightarrow (\text{int} \rightarrow \text{int})$ .

2. Quel est le type de  $\text{fun } g \rightarrow g \ (g \ 7)$  ?

$$\frac{\frac{\frac{}{g : \text{int} \rightarrow \text{int} \vdash g : \text{int} \rightarrow \text{int}} \mathcal{T}_v}{\Gamma \vdash g : \text{int} \rightarrow \text{int}} \mathcal{T}_v \quad \frac{}{\Gamma \vdash 7 : \text{int}} \mathcal{T}_k}{g : \text{int} \rightarrow \text{int} \vdash g \ 7 : \text{int}} \mathcal{T}_p}{\emptyset \vdash \text{fun } g \rightarrow g \ (g \ 7) : (\text{int} \rightarrow \text{int}) \rightarrow \text{int}} \mathcal{T}_f$$

---

2. On peut toujours étendre  $\Gamma$  ainsi, modulo  $\alpha$ -conversion.

## 2 Propriétés du système de types.

**Lemme 1.**  $\triangleright$  Si  $\Gamma \vdash e : \tau$  alors  $\mathcal{V}\ell(e) \subseteq \text{dom}(\Gamma)$ .

$\triangleright$  *Affaiblissement.* Si  $\Gamma \vdash e : \tau$  alors

$$\forall x \notin \text{dom}(\Gamma), \forall \tau_0, \quad \Gamma, x : \tau_0 \vdash e : \tau.$$

$\triangleright$  *Renforcement.* Si  $\Gamma, x : \tau_0 \vdash e : \tau$ , et si  $x \notin \mathcal{V}\ell(e)$  alors on a le typage  $\Gamma \vdash e : \tau$ .

**Preuve.** Par induction sur la relation de typage (5 cas). □

### 2.1 Propriété de progrès.

**Lemme 2.** 1. Si  $\emptyset \vdash e : \text{int}$  et  $e \not\rightarrow$  alors, il existe  $k \in \mathbb{Z}$  tel que  $e = k$ .

2. Si  $\emptyset \vdash e : \tau_1 \rightarrow \tau_2$  et  $e \not\rightarrow$  alors il existe  $x$  et  $e_0$  tels que l'on ait  $e = \text{fun } x \rightarrow e_0$ .

**Preuve.** Vu en TD. □

**Proposition 1** (Propriété de progrès). Si  $\emptyset \vdash e : \tau$  alors on a la disjonction :

1. soit  $e$  est une valeur ;
2. soit il existe  $e'$  telle que  $e \rightarrow e'$ .

#### Remarque 4.

- $\triangleright$  Si  $\emptyset \vdash e_1 e_2 : \tau$  alors il existe  $e'$  tel que  $e_1 e_2 \rightarrow e'$ .
- $\triangleright$  Si  $\emptyset \vdash e_1 + e_2 : \tau$  alors il existe  $e'$  tel que  $e_1 + e_2 \rightarrow e'$ .

**Remarque 5.** Par le typage, on a exclu les expressions bloquées car « mal formées » (e.g.  $3\ 2$  ou  $3 + (\text{fun } x \rightarrow x)$ ).

## 2.2 Propriété de préservation.

Cette propriété a plusieurs noms : préservation du typage, réduction assujettie, *subject reduction*.

**Lemme 3** (typage et substitution). Si l'on a le typage  $\emptyset \vdash v : \tau_0$  et  $\Gamma, x : \tau_0 \vdash e : \tau$  alors on a  $\Gamma \vdash e[v/x] : \tau$

**Preuve.** On prouve cette propriété par induction sur  $e$ . Il y a 5 cas.

- ▷ Cas  $e = y$ . On a deux sous-cas.
  - 1<sup>er</sup> sous-cas  $x \neq y$ . Dans ce cas,  $e[v/x] = y$ . Il faut montrer  $\Gamma \vdash y : \tau$  sachant que  $\Gamma, x : \tau_0 \vdash y : \tau$ . On applique le lemme de renforcement.
  - 2<sup>nd</sup> sous-cas  $x = y$ . Dans ce cas,  $e[v/x] = v$ . Il faut montrer que  $\Gamma \vdash v : \tau$ . Or, on sait que  $\Gamma, x : \tau_0 \vdash x : \tau$  (d'où  $\tau = \tau_0$ ) et  $\emptyset \vdash v : \tau_0$ . On conclut par affaiblissement.
- ▷ Les autres cas sont en exercice.

□

**Proposition 2** (Préservation du typage). Si  $\emptyset \vdash e : \tau$ , et  $e \rightarrow e'$  alors  $\emptyset \vdash e' : \tau$ .

**Preuve.** On montre la propriété par induction sur  $\emptyset \vdash e : \tau$ . Il y a 5 cas.

- ▷ Cas  $\mathcal{T}_v$ . C'est absurde! (On n'a pas  $\emptyset \vdash x : \tau$ .)
- ▷ Cas  $\mathcal{T}_f$ . Si  $(\text{fun } x \rightarrow e) \rightarrow e'$  alors ... On peut conclure immédiatement car les fonctions sont des valeurs, elles ne se réduisent donc pas.
- ▷ Cas  $\mathcal{T}_k$ . C'est le même raisonnement.
- ▷ Cas  $\mathcal{T}_a$ . On a  $e = e_1 e_2$ . On sait qu'il existe  $\tau_0$  un type tel que  $\emptyset \vdash e_1 : \tau_0 \rightarrow \tau (H_1)$  et  $\emptyset \vdash e_2 : \tau_0 (H_2)$ . On a également

les hypothèses d'induction :


- $(H'_1)$  : si  $e_1 \rightarrow e'_1$  alors  $\emptyset \vdash e'_1 : \tau_0 \rightarrow \tau$  ;
- $(H'_2)$  : si  $e_2 \rightarrow e'_2$  alors  $\emptyset \vdash e'_2 : \tau_0$ .

On doit montrer que si  $e_1 e_2 \rightarrow e'$  alors  $\emptyset \vdash e' : \tau$ . Supposons que  $e_1 e_2 \rightarrow e'$ , il y a 3 sous-cas.

- *Sous-cas  $\mathcal{R}_{\text{ad}}$* . Cela veut dire que  $e_2 \rightarrow e'_2$  et  $e' = e_1 e'_2$ . On conclut  $\emptyset \vdash e_1 e'_2 : \tau$  par  $(H'_2)$  et  $(H_1)$ .
- *Sous-cas  $\mathcal{R}_{\text{ag}}$* . Cela veut dire que  $e_1 \rightarrow e'_1$  et  $e' = e'_1 e_2$ . On conclut  $\emptyset \vdash e'_1 e_2 : \tau$  par  $(H'_1)$  et  $(H_2)$ .
- *Sous-cas  $\mathcal{R}_\beta$* . On a  $e_1 = \text{fun } x \rightarrow e_0$ ,  $e_2 = v$  et finalement  $e' = e_0[v/x]$ . On doit montrer  $\emptyset \vdash e_0[v/x] : \tau$ . De plus,  $(H_1)$  s'énonce par  $\emptyset \vdash \text{fun } x \rightarrow e_0 : \tau_0 \rightarrow \tau$ . Nécessairement (c'est un « inversion » en Rocq), cela provient de  $x : \tau_0 \vdash e_0 : \tau$ . On en conclut par le lemme de substitution.

▷ Cas  $\mathcal{T}_p$ . Lissé en exercice. □

**Remarque 6.** Avec les propriétés de progrès et préservation implique qu'il n'y a pas de « mauvaises surprises » à l'exécution. On a, en un sens, nettoyé le langage FUN.



C'est la considération d'un langage *statiquement typé*. On aime savoir qu'OCaml ou Rust ont, pour la sémantique et le système de types, une propriété de progrès et de préservation.

**Exercice 1.** Trouver  $e$  et  $e'$  deux expressions telles que  $\emptyset : e' : \tau$  et  $e \rightarrow e'$  mais que l'on ait pas  $\emptyset \vdash e : \tau$ .

**Solution.** Il suffit de trouver une valeur non typable  $e_1$ , par exemple  $\text{fun } x \rightarrow (x \ x)$  ou  $\text{fun } x \rightarrow (19 \ 27)$ , puis de considérer

$$e = (\text{fun } x \rightarrow 3) \ e_1 \rightarrow 3.$$

Or, 3 est typable mais  $e$  non.

### 3 Questions en lien avec la relation de typage.

▷ *Typabilité.* Pour  $e$  donné, existe-t-il  $\Gamma, \tau$  tels que  $\Gamma \vdash e : \tau$ ?

- ▷ *Vérification/Inférence de types.* Pour  $\Gamma$  et  $e$  donnés, existe-t-il  $\tau$  tel que l'on ait  $\Gamma \vdash e : \tau$ ? (▷ OCaml)
- ▷ *Habitation.* Pour  $\tau$  donné, existe-t-il  $e$  tel que  $\emptyset \vdash e : \tau$ ? (▷ Rocq<sup>3</sup>)

## 4 Inférence de types.

### 4.1 Typage et contraintes.

**Exemple 2.** Dans une version étendue de FUN (on se rapproche plus au OCaml), si l'on considère le programme :

```
let rec f x g=
  ...g x ...
  ...if g f then ... else ...
  ...let h = x 7 in ...
```

On remarque que

- ▷  $x$  et  $f$  ont le même type;
- ▷  $g$  a un type  $? \rightarrow \text{bool}$ ;
- ▷  $x$  a un type  $\text{int} \rightarrow ?$ .

On doit donc lire le programme, et « prendre des notes ». Ces « notes » sont des contraintes que doivent vérifier le programme.

**Exemple 3.** On souhaite déterminer le type  $\tau$  tel que


$$\emptyset \vdash \text{fun } g \rightarrow g (g 7) : \tau.$$

(On sait que  $\tau = (\text{int} \rightarrow \text{int}) \rightarrow \text{int}$ .)

On construit l'arbre de l'expression (l'AST) :

---

3. On peut voir une preuve d'un théorème en Rocq comme fournir une preuve qu'il existe une expression  $e$  avec type  $\tau$ .



On procède en plusieurs étapes :

1. On ajoute des inconnues de types  $T_1, T_2, T_3, \text{etc}$  (en vert).
2. On écrit des contraintes faisant intervenir les  $T_i$  (en orange/marron).

$$\begin{aligned}
 T_0 &= T_g \rightarrow T_1 \\
 T_g &= T_2 \rightarrow T_1 \\
 T_g &= \text{int} \rightarrow T_1.
 \end{aligned}$$

3. On résout les contraintes pour obtenir

$$T_0 = (\text{int} \rightarrow \text{int}) \rightarrow \text{int}.$$


**Exemple 4 (Cas limites).**  $\triangleright$  L'expression `fun x → 7` admet une infinité de types ( $T_x \rightarrow \text{int}$ ).

- $\triangleright$  L'expression `(fun x → 7) (fun z → z)` a toujours le type `int` mais admet une infinité de dérivations.

**Exemple 5 (Et quand ça ne marche pas ?).** On essaie d'inférer le

type de l'expression

`fun x → x + (x 2).`



Les contraintes sont :

$$\begin{aligned}
 T_0 &= T_x \rightarrow T_1 \\
 T_1 &= T_x = T_2 = \text{int} \\
 T_x &= \text{int} \rightarrow T_2.
 \end{aligned}$$

**Catastrophe !** On ne peut pas résoudre ce système de contraintes (on ne peut pas avoir  $T_x = \text{int}$  et  $T_x = \text{int} \rightarrow T_2$  en même temps). L'expression n'est donc pas typable.

**Définition 3.**  $\triangleright$  On se donne un ensemble infini IType d'inconnues de type, notées  $T, T_1, T', \text{etc.}$

$\triangleright$  On définit les *types étendus*, notés  $\hat{\tau}$ , par la grammaire :

$$\hat{\tau} ::= \text{int} \mid \hat{\tau}_1 \rightarrow \hat{\tau}_2 \mid T.$$

- ▷ L'ensemble des types (*resp.* étendus) est noté  $\mathbf{Typ}$  (*resp.*  $\widehat{\mathbf{Typ}}$ ).
- ▷ Les environnements de types étendus sont notés  $\widehat{\Gamma}$ .
- ▷ Ainsi défini, tout  $\tau$  est un  $\hat{\tau}$ , tout  $\Gamma$  est un  $\widehat{\Gamma}$ .
- ▷ Un  $\hat{\tau}$  est dit *constant* s'il ne contient pas d'inconnue de type (*i.e.* si c'est un  $\tau$ ).

**Définition 4.** Une *contrainte de typage* est une paire de types étendus<sup>4</sup>, notée  $\hat{\tau}_1 \stackrel{?}{=} \hat{\tau}_2$ , ou parfois  $\hat{\tau}_1 = \hat{\tau}_2$ .

On se donne  $e \in \mathbf{FUN}$ . On suppose que toutes les variables liées de  $e$  sont :

- ▷ distinctes deux à deux ;
- ▷ différentes de toutes les variables libres de  $e$ .

On se donne  $\widehat{\Gamma}$  tel que  $\mathcal{V}\ell(e) \subseteq \text{dom}(\widehat{\Gamma})$ . On choisit  $T \in \mathbf{IType}$ .




On définit un ensemble de contraintes, notée  $\mathbf{CT}(e, \widehat{\Gamma}, T)$  par induction sur  $e$ , il y a 5 cas :

- ▷  $\mathbf{CT}(e_1 + e_2, \widehat{\Gamma}, T) = \mathbf{CT}(e_1, \widehat{\Gamma}, T_1) \cup \mathbf{CT}(e_2, \widehat{\Gamma}, T_2) \cup \{T_1 \stackrel{?}{=} \mathbf{int}, T_2 \stackrel{?}{=} \mathbf{int}, T \stackrel{?}{=} \mathbf{int}\}$
- ▷  $\mathbf{CT}(e_1 e_2, \widehat{\Gamma}, T) = \mathbf{CT}(e_1, \widehat{\Gamma}, T_1) \cup \mathbf{CT}(e_2, \widehat{\Gamma}, T_2) \cup \{T_1 \stackrel{?}{=} T_2 \rightarrow T\}$
- ▷  $\mathbf{CT}(x, \widehat{\Gamma}, T) = \{T \stackrel{?}{=} \widehat{\Gamma}(x)\}$
- ▷  $\mathbf{CT}(k, \widehat{\Gamma}, T) = \{T \stackrel{?}{=} \mathbf{int}\}$
- ▷  $\mathbf{CT}(\text{fun } x \rightarrow e, \widehat{\Gamma}, T) = \mathbf{CT}(e, (\widehat{\Gamma}, x : T_x), T_2) \cup \{T \stackrel{?}{=} T_1 \rightarrow T_2\}$

où les variables  $T_1, T_2, T_x$  sont *fraîches* (on notera par la suite  $\mathbb{I} T_1, T_2, T_x$ ).

4. **Attention** c'est une paire, pas un couple.

**Remarque 7.** On peut résumer les cas « plus », « application » et « abstraction ».



$$T_0 = T_1 = T_2 = \text{int}$$

$$T_1 = T_2 \rightarrow T_0$$

$$T_0 = T_1 \rightarrow T_2$$

**Définition 5.** Soit  $C$  un ensemble de contraintes de typage. On note  $\text{Supp}(C)$ , le *support* de  $C$ , l'ensemble des inconnues de type mentionnées dans  $C$ .

Une *solution*  $\sigma$  de  $C$  est un dictionnaire sur  $(\text{ITyp}, \widehat{\text{Typ}})$  tel que  $\text{dom}(\sigma) \supseteq \text{Supp}(C)$  et que  $\sigma$  égalise toutes les contraintes de  $C$ .

Pour  $(\hat{\tau}_1 \stackrel{?}{=} \hat{\tau}_2) \in C$ , on dit que  $\sigma$  égalise  $\hat{\tau}_1 \stackrel{?}{=} \hat{\tau}_2$  signifie que  $\sigma(\hat{\tau}_1)$  et  $\sigma(\hat{\tau}_2)$  sont le même type étendu.

Il reste à définir  $\sigma(\hat{\tau})$ , le résultat de l'application de  $\sigma$  à  $\hat{\tau}$ , par induction sur  $\hat{\tau}$ , il y a trois cas :

- ▷  $\sigma(\hat{\tau}_1 \rightarrow \hat{\tau}_2) = \sigma(\hat{\tau}_1) \rightarrow \sigma(\hat{\tau}_2)$  ;
- ▷  $\sigma(\text{int}) = \text{int}$  ;
- ▷  $\sigma(T)$  est le type étendu associé à  $T$  dans  $\sigma$ .

**Exemple 6.** Avec  $\sigma = [T_1 \mapsto \text{int}, T_2 \mapsto (\text{int} \rightarrow T_3)]$ , on a donc

$$\sigma(T_1 \rightarrow T_2) = \text{int} \rightarrow (\text{int} \rightarrow T_3).$$

**Exemple 7.** La contrainte  $T_1 \stackrel{?}{=} T_2 \rightarrow T_3$  est égalisée par la solution  $\sigma = [T_1 \mapsto T_2 \rightarrow \text{int}, T_3 \mapsto \text{int}]$ .

**Définition 6.** Une *solution constante* de  $C$  est un dictionnaire sur  $(\text{ITyp}, \text{Typ})$  (et pas  $(\text{ITyp}, \widehat{\text{Typ}})$ ) qui est une solution de  $C$ .

**Proposition 3.** Soit  $e \in \text{FUN}$  et soit  $\Gamma$  tel que  $\mathcal{V}\ell(e) \subseteq \text{dom}(\Gamma)$ . Soit  $T \in \text{ITyp}$ . Si  $\sigma$  est une solution constante de  $\text{CT}(e, \Gamma, T)$ , alors  $\Gamma \vdash e : \tau$  où  $\tau = \sigma(T)$ .

**Preuve.** On procède par induction sur  $e$ ; il y a 5 cas.

▷ Dans le cas  $e = e_1 e_2$ , on écrit

$$\text{CT}(e, \Gamma, T) = \text{CT}(e_1, \Gamma, T_1) \cup \text{CT}(e_2, \Gamma, T_2) \cup \{T_1 \stackrel{?}{=} T_2 \rightarrow T\},$$

où  $\mathbb{I} T_1, T_2$ . Soit  $\sigma$  une solution constante de  $\text{CT}(e, \Gamma, T)$ . Alors,

- $\sigma$  est une solution constante de  $\text{CT}(e_1, \Gamma, T_1)$ ;
- $\sigma$  est une solution constante de  $\text{CT}(e_2, \Gamma, T_1)$ .

Et, par induction, on sait que

- $\Gamma \vdash e_1 : \sigma(T_1)$ ;
- $\Gamma \vdash e_2 : \sigma(T_2)$ .

Par ailleurs,  $\sigma(T_1) = \sigma(T_2) \rightarrow \sigma(T)$ . On en conclut en appliquant  $\mathcal{T}_a$ .

▷ Les autres cas se traitent similairement. □

**Proposition 4.** Supposons  $\Gamma \vdash e : \tau$ . Alors, pour tout  $T \in \text{ITyp}$ , il existe  $\sigma$  une solution constante de  $\text{CT}(e, \Gamma, T)$  telle que l'on ait l'égalité  $\sigma(T) = \tau$ .

**Preuve.** On procède par induction sur  $e$ . Il y a 5 cas.

▷ Dans le cas  $e = e_1 e_2$ , supposons  $\Gamma \vdash e_1 e_2 : \tau$ . Nécessairement, cette dérivation provient de  $\Gamma \vdash e_1 : \tau_2 \rightarrow \tau$  et aussi  $\Gamma \vdash e_2 : \tau_2$ .

Soit  $T_0 \in \text{ITyp}$ , on a

$$\text{CT}(e, \Gamma, T_0) = \text{CT}(e_1, \Gamma, T_1) \cup \text{CT}(e_2, \Gamma, T_2) \cup \{T_1 \stackrel{?}{=} T_2 \rightarrow T_0\}.$$

Et, par induction, on a  $\sigma_1$  et  $\sigma_2$  des solutions constantes de  $\text{CT}(e_1, \Gamma, T_1)$  et  $\text{CT}(e_2, \Gamma, T_2)$  avec  $\sigma_1(T_1) = \tau_2 \rightarrow \tau$  et  $\sigma_2(T_2) = \tau_2$ .

On définit  $\sigma$  en posant :

- $\sigma(T) = \sigma_1(T)$  si  $T \in \text{Supp}(\text{CT}(e_1, \Gamma, T_1))$ ;
- $\sigma(T) = \sigma_2(T)$  si  $T \in \text{Supp}(\text{CT}(e_2, \Gamma, T_2))$ ;
- $\sigma(T_0) = \tau$ .

On vérifie bien que  $\sigma$  est solution constante de  $\text{CT}(e, \Gamma, T_0)$ .

▷ Les autres cas se traitent similairement. □

**Théorème 1.** On a  $\Gamma \vdash e : \tau$  si, et seulement si  $\forall T \in \text{ITyp}$ , l'ensemble de contraintes  $\text{CT}(e, \Gamma, T)$  admet une solution constante  $\sigma$  tel que  $\sigma(T) = \tau$ . □

**Remarque 8.** On a caractérisé l'ensemble des dérivations de  $\Gamma \vdash e : \tau$  avec l'ensemble des solutions constantes de  $\text{CT}(e, \Gamma, T)$ .

## 4.2 Termes et unification.

On va momentanément oublier FUN, pour généraliser à tout ensemble d'expressions. Ceci permet d'appliquer cet algorithme à une grande variété de « langages ».

**Définition 7.** On se donne

- ▷ un ensemble fini  $\Sigma$  de *constantes*, notées  $f, g, a, b$  où chaque constante  $f \in \Sigma$  a un entier naturel nommé *arité*;
- ▷ un ensemble infini  $V$  d'*inconnues*/de *variables*/de *variables*

*d'unification*; notées  $X, Y, Z$  (mais parfois  $x, y, z$ ).

L'ensemble  $\mathbb{T}(\Sigma, V)$  des *termes* sur  $(\Sigma, V)$ , notés  $t, u$ , etc, est défini de manière inductive, ce qui est décrit par la grammaire :

$$t ::= f^k(t_1, \dots, t_k) \mid X,$$

où  $f$  est une constante d'arité  $k$ .

**Remarque 9.** L'intuition est que l'on étend, comme lors du passage de  $\mathbf{Typ}$  à  $\widehat{\mathbf{Typ}}$ , un langage de départ pour ajouter des inconnues. La définition inductive a  $|\Sigma| + 1$  constructeurs.

Intuitivement, les  $X \in V$  ne fait pas partie du langage de départ. Il n'y a pas de liens pour  $X$ .

**Exemple 8.** Avec  $\Sigma = \{f^2, g^1, a^0, b^0\}$ ,

$$t_0 := f(g(a), f(X, f(Y, g(X)))) \in \mathbb{T}(\Sigma, V)$$

est un terme.

**Définition 8.** On définit  $\mathbf{Vars}(t)$  l'ensemble des inconnues/variables de  $t$  par induction sur  $t$ . Il y a deux familles de cas :

- ▷  $\mathbf{Vars}(f(t_1, \dots, t_k)) = \mathbf{Vars}(t_1) \cup \dots \cup \mathbf{Vars}(t_k)$ ;
- ▷  $\mathbf{Vars}(X) = \{X\}$ .

**Exemple 9.** Avec l'expression  $t_0$  précédente, on a

$$\mathbf{Vars}(t_0) = \{X, Y\}.$$

**Définition 9.** Une *substitution*, notée  $\sigma, \sigma_1, \sigma'$ , etc, est un dictionnaire sur  $(V, \mathbb{T}(\Sigma, V))$ .

Si  $X \in \text{dom}(\sigma)$ , on dit que  $\sigma$  est *définie* en  $X$ .

Soit  $\sigma$  une substitution et  $t \in \mathbb{T}(\Sigma, \mathbb{V})$ . Le résultat de l'application de  $\sigma$  à  $t$ , noté  $\sigma(t)$ , est défini par induction sur  $t$ , il y a deux familles de cas :

- ▷  $\sigma(f(t_1, \dots, t_k)) = f(\sigma(t_1), \dots, \sigma(t_k))$ ;
- ▷  $\sigma(X) = X$  si  $X \notin \text{dom}(\sigma)$ ;
- ▷  $\sigma(X)$  est le terme associé à  $X$  dans  $\sigma$  si  $X \in \text{dom}(\sigma)$ .

**Exemple 10.** Avec  $\sigma = [X \mapsto g(Y), Y \mapsto b]$ , on a

$$\sigma(t_0) = f(g(a), \underbrace{f(g(Y), f(b, g(g(Y))))}_{\text{}}).$$

**Attention !** On n'a pas de terme en  $g(b)$  : c'est une substitution *simultanée*.

**Note 2.** On rappelle qu'un dictionnaire peut être vu comme un ensemble fini de couples  $(X, t)$  avec  $X \in \mathbb{V}$  et  $t \in \mathbb{T}(\Sigma, \mathbb{V})$  tel que, pour toute variable  $X \in \mathbb{V}$ , il y a au plus un couple de la forme  $(X, t)$  dans la liste.

On utilise la notation  $[t/X]$  pour représenter la notation  $[X \mapsto t]$ . Ceci est utiliser que lorsqu'on ne change qu'une variable.

**Définition 10.** Un *problème d'unification* est la donnée d'un ensemble fini de paires de termes (les contraintes) dans  $\mathbb{T}(\Sigma, \mathbb{V})$ . On note un tel problème  $\mathcal{P} = \{t_1 \stackrel{?}{=} u_1, \dots, t_k \stackrel{?}{=} u_k\}$ .

Une *solution*, un *unificateur*, d'un tel  $\mathcal{P}$  est une substitution  $\sigma$  telle que, pour toute contrainte  $t \stackrel{?}{=} u$  dans  $\mathcal{P}$ ,  $\sigma(t)$  et  $\sigma(u)$  sont le même terme, ce que l'on note  $\sigma(t) = \sigma(u)$ .

On note  $U(\mathcal{P})$  l'ensemble des unificateurs de  $\mathcal{P}$ .

**Exemple 11.** Avec le problème d'unification

$$\mathcal{P}_1 = \{f(a, g(X)) \stackrel{?}{=} f(Z, Y), g(T) \stackrel{?}{=} g(Z)\},$$

les substitutions

- ▷  $\sigma_1 = [Z \mapsto a, Y \mapsto g(X), T \mapsto a]$  ;
- ▷  $\sigma_2 = [Z \mapsto a, Y \mapsto g(b), T \mapsto a, X \mapsto b]$  ;

sont des solutions de  $\mathcal{P}_1$ . Mais,

$$\sigma_3 = [Z \mapsto f(b, b), T \mapsto f(b, b), Y \mapsto g(b), X \mapsto b]$$

n'est pas une solution.

*Laquelle des solutions  $\sigma_1$  et  $\sigma_2$  est meilleure ?* On remarque que  $\sigma_2 = [b/X] \circ \sigma_1$  (où la composition est définie « comme on le pense »<sup>5</sup>). Ainsi,  $\sigma_1$  est « plus général » que  $\sigma_2$  ;  $\sigma_2$  est un « cas particulier » de  $\sigma_1$ .

**Exemple 12 (Aucune solution).** Les problèmes

- ▷  $\mathcal{P}_2 = \{f(X, Y) \stackrel{?}{=} g(Z)\}$  ;
- ▷  $\mathcal{P}_3 = \{f(X, Y) \stackrel{?}{=} X\}$

n'ont aucune solution :  $U(\mathcal{P}_2) = U(\mathcal{P}_3) = \emptyset$ .

### 4.3 Algorithme d'unification (du premier ordre).

**Définition 11.** Un *état* est soit un couple  $(\mathcal{P}, \sigma)$ , soit  $\perp$  (*l'état d'échec*).

Un état de la forme  $(\emptyset, \sigma)$  est appelé *état de succès*.

Un état qui n'est, ni échec, ni succès, peut s'écrire sous la forme  $(\{t \stackrel{?}{=} t'\} \sqcup \mathcal{P}, \sigma)$ , la contrainte  $t \stackrel{?}{=} t'$  étant choisie de manière non-déterministe.

5. Elle sera définie formellement ci-après.

On définit une relation binaire  $\rightarrow$  entre états par :

- ▷  $\perp \not\rightarrow$  ;
- ▷  $(\emptyset, \sigma) \not\rightarrow$  ;
- ▷ Il ne reste que les cas ni succès, ni échec, que l'on traite par la disjonction de cas :
  1.  $(\{f(t_1, \dots, t_k) \stackrel{?}{=} f(u_1, \dots, u_n) \sqcup \mathcal{P}, \sigma\}) \rightarrow (\{t_1 \stackrel{?}{=} u_1, \dots, t_k \stackrel{?}{=} u_k\} \cup \mathcal{P}, \sigma)$  ;
  2.  $(\{f(t_1, \dots, t_k) \stackrel{?}{=} g(u_1, \dots, u_n) \sqcup \mathcal{P}, \sigma\}) \rightarrow \perp$  si  $f \neq g$  ;
  3.  $(\{X \stackrel{?}{=} t\} \sqcup \mathcal{P}, \sigma) \rightarrow (\mathcal{P}[t/X], [t/X] \circ \sigma)$  où
    - $X \notin \text{Vars}(t)$ ,
    - $\mathcal{P}[t/X] = \{u[t/X] \stackrel{?}{=} u'[t/X] \mid (u \stackrel{?}{=} u') \in \mathcal{P}\}$ ,
    - et  $[t/X] \circ \sigma$  est la substitution telle que, quel que soit  $Y \in \mathbf{V}$ ,  $([t/X] \circ \sigma)(Y) = (\sigma(Y))[t/X]$  ;
  4.  $(\{X \stackrel{?}{=} t\} \sqcup \mathcal{P}, \sigma) \rightarrow \perp$  si  $X \in \text{Vars}(t)$  et  $t \neq X$  ;
  5.  $(\{X \stackrel{?}{=} X\} \sqcup \mathcal{P}, \sigma) \rightarrow (\mathcal{P}, \sigma)$ .

L'état initial de l'algorithme correspond à  $(\mathcal{P}, \emptyset)$  : le problème  $\mathcal{P}$  muni de la substitution vide  $\emptyset$ .

**Exemple 13.** On applique l'algorithme d'unification comme

montré ci-dessous :

$$\begin{aligned}
 & \underbrace{\{f(a, X) \stackrel{?}{=} f(Y, a), g(X) \stackrel{?}{=} g(Y)\}}_{\text{choix}}, \emptyset \\
 \rightarrow & \underbrace{\{a \stackrel{?}{=} Y, X \stackrel{?}{=} a, g(X) \stackrel{?}{=} g(Y)\}}_{\text{choix}}, \emptyset \\
 \rightarrow & \underbrace{\{X \stackrel{?}{=} a, g(X) \stackrel{?}{=} g(a)\}}_{\text{choix}}, [Y \mapsto a] \\
 \rightarrow & \underbrace{\{g(a) \stackrel{?}{=} g(a)\}}_{\text{choix}}, [Y \mapsto a, X \mapsto a] \\
 \rightarrow & \underbrace{\{a \stackrel{?}{=} a\}}_{\text{choix}}, [Y \mapsto a, X \mapsto a] \\
 \rightarrow & \emptyset, [Y \mapsto a, X \mapsto a] \\
 & \cdot
 \end{aligned}$$

On peut remarquer que l'ensemble des clés de  $\sigma$  n'apparaît pas dans le problème ni dans les autres termes de la substitution : lorsqu'on ajoute une clé, elle disparaît du problème.

**Définition 12.** Un état  $(\mathcal{P}, \sigma)$  est en *forme résolue* si, pour toute clé  $X \in \text{dom}(\sigma)$ , alors  $X$  n'apparaît pas dans  $\mathcal{P}$  et, quel que soit la clé  $Y \in \text{dom}(\sigma)$  alors  $X \notin \text{Vars}(\sigma(Y))$ .

**Remarque 10 (Notation).** Une substitution  $\sigma$  peut être vue comme un problème d'unification, que l'on note  $\overset{?}{\sigma}$ . (On passe d'un ensemble de couples à un ensemble de paires.)

**Proposition 5.** Si  $(\mathcal{P}_0, \sigma_0)$  est en forme résolue et  $(\mathcal{P}_0, \sigma_0) \rightarrow (\mathcal{P}_1, \sigma_1)$  alors  $(\mathcal{P}_1, \sigma_1)$  est en forme résolue et

$$U(\mathcal{P}_0 \cup \overset{?}{\sigma}_0) = U(\mathcal{P}_1 \cup \overset{?}{\sigma}_1).$$

**Preuve.** La vraie difficulté se trouve dans le 3ème cas (les cas 1 et 5 sont immédiats). Pour cela, on utilise le lemme « technique » ci-dessous.

**Lemme 4.** Si  $X \notin \text{dom}(\sigma)$  alors

$$[t/X] \circ \sigma = [X \mapsto t, Y_1 \mapsto (\sigma(Y_1))[t/X], \dots, Y_l \mapsto (\sigma(Y_k))[t/X]],$$

où  $\text{dom}(\sigma) = \{Y_1, \dots, Y_k\}$ .  $\square$

$\square$

**Proposition 6.** On note  $\rightarrow^*$  la clôture réflexive et transitive de la relation  $\rightarrow$ .

1. Un *unificateur le plus général* (*mgu*<sup>6</sup> dans la littérature anglaise) est une solution  $\sigma \in \text{U}(\mathcal{P})$  telle que, quelle que soit  $\sigma' \in \text{U}(\mathcal{P})$ , il existe  $\sigma''$  telle que  $\sigma' = \sigma'' \circ \sigma$ .

Si  $(\mathcal{P}, \emptyset) \rightarrow^* (\emptyset, \sigma)$  alors  $\sigma$  est un unificateur le plus général de  $\mathcal{P}$ .

2. Si  $(\mathcal{P}, \emptyset) \rightarrow^* \perp$  alors  $\text{U}(\mathcal{P}) = \emptyset$ .

**Preuve.** 1. On montre par induction sur  $(\mathcal{P}, \emptyset) \rightarrow^* (\emptyset, \sigma)$  l'égalité  $\text{U}(\mathcal{P}) = \text{U}(\overset{?}{\sigma})$  à l'aide de la proposition précédente. Puis, on conclut avec le lemme suivant.

**Lemme 5.** Pour toute substitution  $\sigma$ , alors  $\sigma$  est un unificateur le plus général de  $\overset{?}{\sigma}$ .

6. Pour *Most Général Unifier*

**Preuve.** Soit  $\sigma' \in U(\overset{?}{\sigma})$  et soit  $X \in V$ . On montre que  $\sigma' \circ \sigma = \sigma'$ .

- ▷ Si  $X \in \text{dom}(\sigma)$ , alors  $\sigma'(\sigma(X)) = \sigma'(X)$  car  $\sigma'$  satisfait la contrainte  $X \stackrel{?}{=} \sigma(X)$ .
- ▷ Si  $X \notin \text{dom}(\sigma)$  alors  $\sigma'(\sigma(X)) = \sigma'(X)$ .

Ainsi  $\sigma' \circ \sigma = \sigma'$ . □

2. On montre que si  $(\mathcal{P}, \emptyset) \rightarrow \perp$  alors  $U(\mathcal{P} \cup \overset{?}{\sigma})$ . Pour le 2nd cas, c'est immédiat. Pour le 4ème cas, on procède par l'absurde. Soit  $\sigma_0$  qui satisfait  $X \stackrel{?}{=} t$  avec  $X \in \text{Vars}(t)$  et  $X \neq t$ . Alors  $\sigma_0(X) = \sigma_0(t)$ , qui contient  $\sigma_0(X)$  et c'est un sous-ensemble strict. Absurde.


On raisonne ensuite par induction sur  $\rightarrow^*$  pour conclure que  $(\mathcal{P}, \emptyset) \rightarrow^* (\mathcal{P}_0, \sigma_0) \rightarrow \perp$ . □

**Lemme 6.** La relation  $\rightarrow$  est terminante (il n'y a pas de chaîne infinie avec cette relation).

**Preuve.** Vue plus tard. □

**Théorème 2.** L'algorithme d'unification calcule un unificateur le plus général si, et seulement si le problème initial a une solution. □

### 4.4 Retour sur l'inférence de types pour FUN.



Ceci conclut notre étude du petit langage fonctionnel FUN.

---

7. L'unificateur le plus général peut contenir des variables dans ses valeurs qui ne sont pas des clés (par exemple lors du typage de `fun x → x`). Il faut donc composer  $\sigma$  avec une substitution « constante » pour effacer ces variables inutilisées.