

**CDuce**

**Un langage fonctionnel pour manipuler des documents  
XML**

Alain Frisch

INRIA Rocquencourt (projet Cristal)

Séminaire IRIT - 16/12/2004

# Plan

- 1 **XML et développement d'applications**
  - XML
  - Développements d'applications XML
- 2 **Approche langage pour XML : abstractions, concepts**
  - Automates d'arbres
  - Motifs
- 3 **©Duce**
  - Interface avec OCaml

# Plan

- 1 XML et développement d'applications**
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts
  - Automates d'arbres
  - Motifs
- 3 ©Duce
  - Interface avec OCaml

# XML

## XML

- Un langage de **balises**.
- Pour représenter des données de nature **arborescente** sous forme textuelle.
- Représentation indépendante de l'application.


## Un exemple

```
<html>
  <head>
    <title>CDuce</title>
  </head>
  <body>
    <p>Please visit the <a href="http://www.cduce.org">CDuce</a> home page.</p>
  </body>
</html>
```

# XML

## Exemple

```
<html>
  <head>
    <title>...</title>
  </head>
  <body>
    <p>...<a href="...">...</a>...</p>
  </body>
</html>
```



# XML

## Utilisations

- Documents : web, bureautique, documentation.
- Format d'échange entre applications de gestion.
- Bases de données.
- Fichiers de configuration, de description d'interface.
- Services web.

# XML : schémas

## Schémas

- Chaque application définit des **contraintes** sur les documents XML qu'elle peut manipuler :
  - balises (nom, structure d'imbrication),
  - attributs (présence, valeurs autorisées),
  - texte (présence).
- Un tel ensemble de contraintes est un **schéma** de données XML.
- Il existe des langages pour écrire des schémas de manière formelle : DTD, XML-Schema, Relax-NG.

# XML : schémas

## DTD simplifiée de HTML

```
<!ELEMENT html (head, body)>
<!ELEMENT head (title)>
<!ELEMENT title (#PCDATA)>
<!ELEMENT body (p | ul | table)*>
<!ELEMENT p (#PCDATA | a)*>
<!ELEMENT a (#PCDATA)>
<!ATTLIST a
  href      CDATA      #IMPLIED
>
<!ELEMENT ul (li)+>
<!ELEMENT li (p | ul | table)*>
```



# XML : schémas

## À quoi servent les schémas ?

- Documentation formelle sur les contraintes en entrée ou les garanties en sortie des applications.
- Outils de validations génériques, indépendants des applications.
- Éditeurs XML dirigés par les schémas.

# Plan

## 1 XML et développement d'applications

- XML
- Développements d'applications XML

## 2 Approche langage pour XML : abstractions, concepts

- Automates d'arbres
- Motifs

## 3 CDuce

- Interface avec OCaml

Intégrer données et applications : ça ne va pas de soi !

### BD relationnelles

- Modèle de données assez simple
- Langage SQL : faiblement typé
- Intégration pauvre dans langages de programmation
- (corollaires en terme de sûreté, sécurité, ...)

### BD objets

...

# Développer avec XML

Niveau 0 : représentation textuelle des documents XML

AWK, sed, Perl

Niveau 1 : vue abstraite

SAX, DOM

Niveau 2 : petits langages spécifiques pour XML, sans types

XSLT, XPath

Niveau 3 : types XML pris avec sérieux

- Data-binding
- Nouveaux langages

# Schémas et applications

## Transformation XML

Schéma A  $\xrightarrow{\text{Programme T}}$  Schéma B

## Garanties

- Le programme T s'engage à fournir un document XML de schéma B si on lui donne un document XML de schéma A.
- **Peut-on le croire ?**


# XML : schémas

## Sûreté des applications

- Tests
- Spécifications et preuves formelles
- Analyses statiques sur langages existants
- Nouveaux langages

# XML : schémas

## Application complexe



Toutes les opérations effectuées sur les documents à l'intérieur de l'application sont-elles légales ?

## Opérations illégales

- Extraire l'attribut href d'un élément <title>.
- Supprimer un élément <li>.

# XML : schémas et types

- Typage dans les langages de programmation : interdire des opérations illégales  
(`1 + 'Hello'`, `customer.shutdown()`).
- Il est naturel de voir les schémas XML comme des **types** de données, à l'intérieur des applications.

XML		langages
schémas	↔	types
documents	↔	valeurs



# XML : schémas et types

## Point de vue des applications

- XML = format de données externes.
  - Les documents XML sont des versions sérialisées des structures de données internes de l'application.
  - Types  $\rightsquigarrow$  schémas.
- XML = format d'échange standardisé.
  - Travailler sur des schémas/données déjà définis.
  - Schémas  $\rightsquigarrow$  types.

# Types et programmation

- Types = représentation concrète des données (C).
  - Types = formules logiques ( $\lambda$ -calcul).
  - Types = actions possibles (Java).
  - Types = structure des données (ML).
- 
- Pour éviter certaines erreurs.
  - Pour compiler (efficacement).
  - Pour structurer le code.
  - Comme documentation. Pour faciliter la maintenance.

# Data-binding

## Traduire les schémas en des types ?

- Schémas XML : grande **souplesse**.
- Types de données des langages : plus **rigides**, moins précis.

### <!ELEMENT ul (li)+>

- Un élément <ul> : séquence non vide d'éléments <li>.
- Produire un élément vide : illégal.
- Extraire le premier, ou le dernier sous-élément : légal.
- Oublier la contrainte « non vide ».
- Travailler avec plusieurs schémas qui définissent des contraintes différentes pour le même élément <ul>.

# Plan


- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts**
  - Automates d'arbres
  - Motifs
- 3 CDuce
  - Interface avec OCaml

# Automates d'arbres


- Généralisation des automates finis.
- Un automate d'arbre définit un ensemble (dit régulier) d'arbres.
- Bonnes propriétés : singletons, clôture par combinaisons booléennes, décidabilité de l'inclusion.
- Dans le cadre de XML, on peut voir les automates comme un formalisme de schémas.
- DTD, XML-Schema +/- automates.

# Encodage en arbres binaires

## XML



## Arbre binaire



# Automates d'arbres et langages XML

Makoto Murata a proposé d'utiliser les automates dans le cadre de SGML dès 1994.

## XDuce (Hosoya, Vouillon, Pierce)

- Types = automates d'arbres. Valeurs = arbres XML.
- Sous-typage = inclusion des langages. (Problème exponentiel, algorithme efficace en pratique, linéaire pour les DTD.)
- Types purement structurels  $\neq$  types nominaux.
- Fertile descendance (XQuery, Xtatic, CDuce, XHaskell, ...)

*Regular Expression Types for XML* (ICFP 2000).

*Regular Expression Pattern Matching for XML* (POPL 2001).

Hosoya, Vouillon, Pierce.

## Types réguliers

$$\vdash v : t$$
 $v ==$ 

```

<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
           <author>[ 'Bastiaan Heeren' ]
           <author>[ 'Jurriaan Hage' ]
           <author>[ 'Doaitse Swierstra' ] ] ] ] ]

```

 $t ==$ 

```

<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
           <author>[ 'Bastiaan Heeren' ]
           <author>[ 'Jurriaan Hage' ]
           <author>[ 'Doaitse Swierstra' ] ] ] ] ]

```



# Types réguliers

 $\vdash v : t$  $v ==$ 

```
<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
            <author>[ 'Bastiaan Heeren' ]
            <author>[ 'Jurriaan Hage' ]
            <author>[ 'Doaitse Swierstra' ] ] ] ] ]
```

 $t ==$ 

```
<program>[
  <date day=String>[
    <invited>[ <title>[ PCDATA ]
              <author>[ PCDATA ] ] ]
    <talk>[ <title>[ PCDATA ]
            <author>[ PCDATA ]
            <author>[ PCDATA ]
            <author>[ PCDATA ] ] ] ] ]
```

# Types réguliers

$$\vdash v : t$$

$v ==$

```
<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
            <author>[ 'Bastiaan Heeren' ]
            <author>[ 'Jurriaan Hage' ]
            <author>[ 'Doaitse Swierstra' ] ] ] ] ]
```

$t ==$

```
<program>[
  <date day=String>[
    <invited>[ Title Author ]
    <talk>[ Title Author Author Author ] ] ]
```

```
type Author = <author>[ PCDATA ]
```

```
type Title = <title>[ PCDATA ]
```

# Types réguliers

$$\vdash v : t$$

$v ==$

```
<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
            <author>[ 'Bastiaan Heeren' ]
            <author>[ 'Jurriaan Hage' ]
            <author>[ 'Doaitse Swierstra' ] ] ] ] ]
```

$t ==$

```
<program>[
  <date day=String>[
    <invited>[ Title Author+ ]
    <talk>[ Title Author+ ] ] ]
```

```
type Author = <author>[ PCDATA ]
```

```
type Title = <title>[ PCDATA ]
```

# Types réguliers

$$\vdash v : t$$

$v ==$

```
<program>[
  <date day="monday">[
    <invited>[ <title>[ 'Conservation of information' ]
              <author>[ 'Thomas Knight, Jr.' ] ] ]
    <talk>[ <title>[ 'Scripting the type-inference process' ]
           <author>[ 'Bastiaan Heeren' ]
           <author>[ 'Jurriaan Hage' ]
           <author>[ 'Doaitse Swierstra' ] ] ] ] ]
```

$t ==$

Program

```
type Program = <program>[ Day* ]
type Day = <date day=String>[ Invited? Talk+ ]
type Invited = <invited>[ Title Author+ ]
type Talk = <talk>[ Title Author+ ]
type Author = <author>[ PCDATA ]
type Title = <title>[ PCDATA ]
```

# Langages fonctionnels, typage

## Paradigme fonctionnel

Un programme est une **expression** à évaluer. Le résultat d'une expression est une valeur.

## Typage

$\Gamma \vdash e : t$

$e$  : expression à typer

$\Gamma$  : environnement (types des variables libres)

$t$  : type possible pour  $e$

## Exemples

$$\frac{\Gamma \vdash e : \text{bool} \quad \Gamma \vdash e_1 : t \quad \Gamma \vdash e_2 : t}{\Gamma \vdash \text{if } e \text{ then } e_1 \text{ else } e_2 : t}$$

$$\frac{\Gamma \vdash e_1 : t \rightarrow s \quad \Gamma \vdash e_2 : t}{\Gamma \vdash e_1 e_2 : s}$$

# Sous-typage

## Subsomption

$t \leq s$  signifie que toute **valeur** de type  $t$  est aussi valeur de type  $s$ . Il est alors légitime d'utiliser une **expression** de type  $t$  dans un contexte qui attend une expression de type  $s$ .

$$\frac{\Gamma \vdash e : t \quad t \leq s}{\Gamma \vdash e : s}$$

## Exemple

Si on dispose d'une fonction de type  $s \rightarrow s'$ , on peut l'appeler avec un argument de type  $t$  si  $t \leq s$ .

# Plan

- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts**
  - Automates d'arbres
  - **Motifs**
- 3 CDuce
  - Interface avec OCaml

# Transducteurs d'arbres

- Ex :  $k$ -pebble transducers (Milo, Suciu, Vianu).
- Modèles de calculs formels, avec propriétés de décidabilité pour type-checking inverse.
- Algorithmes de décision coûteux, pas implémentés.
- On peut envisager de construire des langages qui utilisent des transducteurs soit comme langage cible, soit comme outil d'analyse.



## Motifs réguliers (XDuce, CDuce, ...)

- Généralisation du pattern-matching de ML.
- Types XML (expressions régulières) + variables de capture.
- Deux visions : transducteurs rudimentaires, ou automates enrichis par de la capture.
- Récursion en largeur et en profondeur.
- Mini langage de requêtes.
- Motifs ambigus : desambiguation (*first match*, *longest match*), non déterminisme, rejet (détection statique), sémantique *all match*.

# Motifs et typage

- Le système de types garantit l'exhaustivité et infère le type (exact) des variables de capture.
- Détection des branches/motifs inutilisés.

# Filtrage : un petit goût de ML

```
match e with <date day=d>_ -> d
```

```
type E = <add>[Int Int] | <sub>[Int Int]
```

```
fun eval (E -> Int)
```

```
  | <add>[ x y ] -> x + y
```

```
  | <sub>[ x y ] -> x - y
```

Les motifs sont des “types avec des variables de capture”

# Filtrage : au delà de ML

- Dispatch sur le type :

```
match e with
| x & Int -> ...
| x & Char -> ...

let doc =
  match (load_xml "doc.xml") with
  | x & DocType -> x
  | _ -> raise "Invalid input !";;
```

# Filtrage : au delà de ML

- Expressions régulières et capture :

```
fun (Invited|Talk -> [Author+]) <_>[ Title x::Author* ] -> x
```

```
fun ([[Invited|Talk|Event]*] -> ([Invited*], [Talk*]))
  [ (i::Invited | t::Talk | _) * ] -> (i,t)
```

```
fun parse_email (String -> (String,String))
  | [ local::_* '@' domain::_* ] -> (local,domain)
  | _ -> raise "Invalid email address"
```

# Filtres (Hosoya)

## Idée

- Un filtrage a la forme  $p_1 \rightarrow e_1 \mid \dots \mid p_n \rightarrow e_n$ .
- On peut voir  $\mid$  comme l'alternation des expressions régulières
- ... et généraliser le filtrage aux autres opérateurs : séquence, étoile, ...

## Exemple

```
((<author>x -> x @ ", ")* (<author>x -> x @ "et "))? (<author>x -> x)
```

## Prolongement

Unifier filtrage, XPath, itérateurs.

# Plan

- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts**
  - Automates d'arbres
  - Motifs
- 3 CDuce
  - Interface avec OCaml

# Templates

- Arbres partiels avec des **trous** nommés.
- On peut brancher un arbre partiel dans un autre.
- Construire progressivement des arbres de manière descendante.
- Au cœur du langage Xact (ex : <bigwig>, Jwig).
- Il est nécessaire de donner un type aux trous. En fait, analyse par interprétation abstraite (inférence de flot).



# Templates

- On peut naturellement voir un template comme une **fonction de première classe**.

$$\frac{\Gamma \vdash e_1 : \{x_1 : t_1; \alpha\} \rightarrow t \quad \Gamma \vdash e_2 : \{\beta\} \rightarrow t_1}{\Gamma \vdash \text{plug}_{x_1} e_1 e_2 : \{\alpha; \beta\} \rightarrow t}$$

- Templates et motifs sont des notions duales.
- Langage avec motifs de première classe ?

# Plan

- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts
  - Automates d'arbres
  - Motifs
- 3 **©Duce**
  - Interface avec OCaml

## Langage :

- orienté XML ;
- centré sur les types ;
- basé sur le filtrage par expression régulières ;
- avec des caractéristiques généralistes ;
- (assez) efficace.

Extension de XDuce avec ordre supérieur, fonctions surchargées, ...

## Scénarios d'utilisation

- Petits “adaptateurs” entre applications XML.
- Applications plus grosses.
- Applications web, web services.
- Couche d'E/S XML pour des applications OCaml.

# Implémentation de CDuce

- $\simeq$  20 000 lignes de code (OCaml).
- Distribution publique depuis juin 2003.
- Implémentation assez efficace (ordre de grandeur des moteurs XSLT et XQuery pour transformations/requêtes équivalentes).
- Prise en compte de tout XML, Unicode, Namespaces. Traduction DTD  $\rightsquigarrow$  types, et partiellement pour XML Schema.
- Quelques dizaines d'utilisateurs.
- Utilisations : sites web statiques, dynamiques (y compris en production), enseignement.
- Système d'interface typé avec OCaml :
  - Utiliser des bibliothèques OCaml existantes.
  - Appeler CDuce depuis OCaml (projets mixtes).

# Types

Les types sont partout dans CDuce :

- Validation statique
  - Ex. : est-ce que ça produit toujours du XHTML valide ?
- Semantique dirigée par les types
  - Dispatch dynamique
  - Fonctions surchargées
- Compilation dirigée par les types
  - Optimisations rendues possibles par les types statiques
  - Évite des opérations inutiles/redondantes à l'exécution
  - Autorise un style plus déclaratif

# Fonctions

- Surchargées, de première classe, sous-typage, partage de nom, partage de code ...

```

type Program = <program>[ Day* ]
type Day = <date day=String>[ Invited? Talk+ ]
type Invited = <invited>[ Title Author+ ]
type Talk = <talk>[ Title Author+ ]

let patch_program (p:[Program], f:(Invited -> Invited) & (Talk -> Talk)): [Program] =
  xtransform p with (Invited | Talk) & x -> [ (f x) ]

let first_author ([Program] -> [Program]; Invited -> Invited; Talk -> Talk)
| [ Program ] & p -> patch_program (p,first_author)
| <invited>[ t a *_ ] -> <invited>[ t a ]
| <talk>[ t a *_ ] -> <talk>[ t a ]

(* On peut remplacer les deux dernières branches par:
   <(k)>[ t a *_ ] -> <(k)>[ t a ]
*)

```

# Un autre exemple

```

type Person = FPerson | MPerson
type FPerson = <person gender="F">[ Name Children ]
type MPerson = <person gender="M">[ Name Children ]
type Children = <children>[Person*]
type Name = <name>[ PCDATA ]

type Man = <man name=String>[ Sons Daughters ]
type Woman = <woman name=String>[ Sons Daughters ]
type Sons = <sons>[ Man* ]
type Daughters = <daughters>[ Woman* ]

let split (MPerson -> Man ; FPerson -> Woman)
  <person gender=g>[ <name>n <children>[(mc::MPerson | fc::FPerson)*] ] ->
  let tag = match g with "F" -> 'woman | "M" -> 'man in
  let s = map mc with x -> split x in
  let d = map fc with x -> split x in
  <(tag) name=n>[ <sons>s <daughters>d ]

```



# Expressivité du filtrage

```
...  
<person gender=g>[...] ->  
  let tag = match g with "F" -> 'woman | "M" -> 'man in  
...
```

peut être remplacé par :

```
<person gender=("F" & (tag := 'woman) | (tag := 'man))>[...] ->
```

ou par :

```
<person>[...] & (FPerson & (tag := 'woman) | MPerson & (tag := 'man)) ->
```

(Plus robuste aux changements de représentation !)

# Aperçu de CDuce

## Types XML

```
type Bib = [ Book* ]  
type Book = <book>[ Title Subtitle? Author+ ]  
type Title = <title>[ PCDATA ]  
type Subtitle = <title>[ PCDATA ]  
type Author = <author>[ PCDATA ]
```

## Fonctions et filtrage

```
let title(Book -> String) <book>[ <title>x_* ] -> x
```

# Aperçu de CDuce

## Types XML

```
type Bib = [ Book* ]
type Book = <book>[ Title Subtitle? Author+ ]
type Title = <title>[ PCDATA ]
type Subtitle = <title>[ PCDATA ]
type Author = <author>[ PCDATA ]
```

## Fonctions et filtrage

```
let title(Book -> String) <book>[ <title>x_* ] -> x

let author(Book -> [ Author+ ]) <book>[ (x::Author | _) * ] -> x
```

# Aperçu de C Duce

## Ordre supérieur

```
type FBook = Book -> String
type ABook = <book print=FBook>[ Title Subtitle? Author+ ]
type ABib = [ ABook* ]
```

Remarque:  $ABook \leq Book$     $ABib \leq Bib$

# Aperçu de CDuce

## Ordre supérieur

```
type FBook = Book -> String
type ABook = <book print=FBook>[ Title Subtitle? Author+ ]
type ABib = [ ABook* ]
  Remarque: ABook ≤ Book  ABib ≤ Bib

let set(<book>c : Book)(f : FBook) : ABook = <book print=f>c
```

# Aperçu de C Duce

## Ordre supérieur

```
type FBook = Book -> String
type ABook = <book print=FBook>[ Title Subtitle? Author+ ]
type ABib = [ ABook* ]
  Remarque: ABook ≤ Book  ABib ≤ Bib

let set(<book>c : Book)(f : FBook) : ABook = <book print=f>c

let prepare(b : Bib) : ABib = map b with x -> set x title
```

## Aperçu de CDuce

## Ordre supérieur

```

type FBook = Book -> String
type ABook = <book print=FBook>[ Title Subtitle? Author+ ]
type ABib = [ ABook* ]
  Remarque: ABook ≤ Book  ABib ≤ Bib

let set(<book>c : Book)(f : FBook) : ABook = <book print=f>c

let prepare(b : Bib) : ABib = map b with x -> set x title

type Ul = <ul>[ Li+ ]
type Li = <li>[ PCDATA ]

let display (ABib -> Ul; ABook -> Li)
| <book print=f>_ & x -> <li>(f x)
| [] -> raise "Empty bibliography"
| p -> <ul>(map p with z -> display z)

```

# Aperçu de CDuce

## Ordre supérieur

```
let change(p : Book -> Bool)(f : FBook)(b : ABib) : ABib =  
  map b with x -> if (p x) then set x f else x
```



# Aperçu de CDuce

## Ordre supérieur

```
let change(p : Book -> Bool)(f : FBook)(b : ABib) : ABib =  
  map b with x -> if (p x) then set x f else x  
  
type HasSub = <_>[ *_ Subtitle *_ ]  
  
let change_if_sub =  
  change (fun (Book -> Bool) HasSub -> 'true | _ -> 'false)  
  
let subtitle_first (Bib -> Bib; ABib -> ABib)  
  [ (x::HasSub | y::_)* ] -> x @ y
```

# Erreurs de types précises

```
type Title = <title>String
type Author = <author>String
type Talk = <talk>[ Title Author+ ]
```

```
let x : Talk = <talk>[ <author>[ 'Alain Frisch' ] <title>[ 'CDuce' ] ]
```

~~

```
let x : Talk = <talk>[ <author>[ 'Alain Frisch' ] <title>[ 'CDuce' ] ]
```

This expression should have type:

'title

but its inferred type is:

'author

which is not a subtype, as shown by the sample:

'author

# Erreurs de types précises

```
type Title = <title>String
type Author = <author>String
type Talk = <talk>[ Title Author+ ]
```

```
fun mk_talk(s : String) : Talk = <talk>[ <title>s ]
```

~~

```
fun mk_talk(s : String) : Talk = <talk>[ <title>s ]
```

This expression should have type:

```
[ Author+ ]
```

but its inferred type is:

```
[ ]
```

which is not a subtype, as shown by the sample:

```
[ ]
```

# Erreurs de types précises

```

type Title = <title>String
type Author = <author>String
type Talk = <talk>[ Title Author+ ]
type Invited = <invited>[ Title Author+ ]
type Day = <date>[ Invited? Talk+ ]

fun (Day -> [Talk+]) <date>[ Invited? x::_*] -> x
fun (Day -> [Talk+]) <date>[ _? x::_*] -> x

```

~~~

```
fun (Day -> [Talk+]) <date>[ _? x::_*] -> x
```

This expression should have type:

```
[ Talk+ ]
```

but its inferred type is:

```
[ Talk* ]
```

which is not a subtype, as shown by the sample:

```
[ ]
```

# Erreurs de types précises

```

type Program = <program>[ Day* ]
type Day = <date day=String>[ Invited? Talk+ ]
type Invited = <invited>[ Title Author+ ]
type Talk = <talk>[ Title Author+ ]
type Author = <author>[ PCDATA ]
type Title = <title>[ PCDATA ]

fun (p : [Program]): [Program] = xtransform p with Invited -> []
fun (p : [Program]): [Program] = xtransform p with <invited>c -> [<talk>c]

fun (p : [Program]): [Program] = xtransform p with Talk -> []

~~
fun (p : [Program]): [Program] = xtransform p with Talk -> []
This expression should have type:
[ Program ]
but its inferred type is:
[ <program>[ <date day = String>[ Invited? ]* ] ]
which is not a subtype, as shown by the sample:
[ <program>[ <date day = "">[ ] ] ]

```

# Plan

- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts
  - Automates d'arbres
  - Motifs
- 3 **©Duce**
  - Interface avec OCaml

# Principales contributions

## Aspects sémantiques

- Extension de XDuce avec l'**ordre supérieur**, en préservant l'approche ensembliste.
- Calcul de **fonctions surchargées**.
- Formulation originale pour les types et motifs récursifs.
- Filtrage : motifs intersection, capture plus puissante, **typage exact**.
- **Enregistrements** extensibles et sous-typage ensembliste.

# Principales contributions

## Aspects algorithmiques

- **Compilation optimisée** du filtrage.
- Modularisation de l'**algorithme de sous-typage** et calcul efficace.
- Implémentation efficace : **représentation des valeurs**.



# Compilation du filtrage

## Un exemple

```
type A = <a>[ A* ]  
type B = <b>[ B* ]  
  
fun (A|B -> Int) A -> 0 | B -> 1  
≈  
fun (A|B -> Int) <a>_ -> 0 | _ -> 1
```

- Tirer partie des informations de **types statiques**
- Autoriser un **style plus déclaratif** ( $\rightsquigarrow$  robuste)

# Plan

- 1 XML et développement d'applications
  - XML
  - Développements d'applications XML
- 2 Approche langage pour XML : abstractions, concepts
  - Automates d'arbres
  - Motifs
- 3 **©Duce**
  - Interface avec OCaml

# Interface avec OCaml

## Appeler OCaml depuis CDuce

- Réutiliser bibliothèques (y compris bindings avec C).
- Structures de données et algorithmes complexes.
- Passer fonctions CDuce comme arguments.
- Instancier fonctions polymorphes avec types CDuce.

## Utiliser une unité CDuce comme un module OCaml

- CDuce comme couche E/S pour applis OCaml.
- Présentation XHTML de résultats, CGI, sérialisation des données internes, gestion des fichiers de config.

# Interface avec OCaml

## Objectifs

On veut :

- Préserver sûreté du typage.
- Éviter d'écrire fonctions de coercions.

## Approche retenue

Une fonction de traduction dans un seul sens :  $\text{OCaml} \implies \text{CDuce}$ .  
Pour un type OCaml  $t$ , déduire un type CDuce  $\hat{t}$  et deux fonctions de coercion  $t \leftrightarrow \hat{t}$ .

Un mapping  $\text{CDuce} \implies \text{OCaml}$  ne peut pas être compatible avec le sous-typage (sauf un mapping constant) !

# Traduction des types

| $t$                                                         | $\hat{t}$                                                          |
|-------------------------------------------------------------|--------------------------------------------------------------------|
| int                                                         | min_int - -max_int                                                 |
| string                                                      | Latin1                                                             |
| $t_1 * t_2$                                                 | $(\hat{t}_1, \hat{t}_2)$                                           |
| $t_1 \rightarrow t_2$                                       | $\hat{t}_1 \rightarrow \hat{t}_2$                                  |
| $A_1 \text{ of } t_1 \mid \dots \mid A_n \text{ of } t_n$   | $(A_1, \hat{t}_1) \mid \dots \mid (A_n, \hat{t}_n)$                |
| $[A_1 \text{ of } t_1 \mid \dots \mid A_n \text{ of } t_n]$ | $(A_1, \hat{t}_1) \mid \dots \mid (A_n, \hat{t}_n)$                |
| $\{l_1 = t_1; \dots; l_n = t_n\}$                           | $\{ l_1 = \hat{t}_1; \dots; l_n = \hat{t}_n \}$                    |
| $t \text{ list}$                                            | $[\hat{t}^*]$                                                      |
| $t \text{ ref}$                                             | $\{ get = [] \rightarrow \hat{t}; set = \hat{t} \rightarrow [] \}$ |
| $t \text{ (abstrait)}$                                      | ! $t$                                                              |
| Cduce.Value.t                                               | Any                                                                |
| Big_int.big_int                                             | Int                                                                |

## Appeler OCaml depuis CDuce

- Soit  $v$  une valeur OCaml de type  $t$ .
- Pour l'utiliser depuis CDuce : appliquer la coercion  $t \rightarrow \hat{t}$ .

```
let home = Sys.getenv "HOME"    (* Latin1 *)
let exists = Sys.file_exists    (* Latin1 -> Bool *)
let listmap = List.map { Int Int } (* (Int -> Int) -> [Int*] -> [Int*] *)
let lst = listmap (fun (x : Int) : Int = x * 2) [ 10 20 30 ] (* [Int*] *)
```

### Caractéristiques OCaml non gérées

- Objets (faisable)
- Tableaux (facile)
- Types récurifs non réguliers (impossible)
- Types abstraits paramétrés (faisable)

# Appeler OCaml depuis CDuce

- L'instanciation des variables de type OCaml par des types CDuce est-elle sûre ?
- Oui !  
Si  $f : \forall \alpha. \tau[\alpha]$ , alors  $f : \tau[X]$  pour n'importe quel ensemble  $X$  de valeurs.

# Appeler CDuce depuis OCaml

- CDuce produit des unités de compilation OCaml (l'interface .cmi est donnée par le programmeur).
- `ocamlc -c a.mli`  $\rightsquigarrow$  `a.cmi`
- `cduce --compile a.cd`  $\rightsquigarrow$  `a.cdo`
- `ocamlc -c -impl a.cdo -pp cdo2ml`  $\rightsquigarrow$  `a.cmo`
- `ocamlc -o prog ... a.cmo ...`  $\rightsquigarrow$  `prog`

a.cd

```
let aux ((Int,Int) -> Int)
| (x, 0 | 1) -> x
| (x, n) -> aux (x * n, n - 1)

let fact (x : Int) : Int = aux (1, x)
```

a.mli

```
val fact: Big_int.big_int -> Big_int.big_int
```



## Autres caractéristiques

- Généralistes : enregistrements, tuples, entiers, exceptions, références, ...
- Chaînes + expressions régulières (types, motifs)
- Connecteurs booléens (types, motifs)
- Autres itérateurs
- Fragment de XPath, `select..from..where...`

# Merci !

<http://www.cduce.org/>