Grammaires et Analyse Syntaxique - Cours 11 Études de cas : langages de données et de programmation

Ralf Treinen

treinen@irif.fr

25 avril 2024

Regard sur quelques langages

- Nous allons réviser des langages de programmation et langages de données que vous avez (éventuellement) vu pendant votre cursus, sous l'aspect de
  - Analyse syntaxique et construction d'un arbre de syntaxe abstrait ;
  - Analyse *sémantique*, par exemple vérification du typage.

Bash

- Les interpréteurs de Bash font une analyse syntaxique à la volée (intercalée avec l'exécution), il n'y a donc pas de construction d'un arbre de syntaxe avant l'exécution.
- La grammaire (originale) de Bash avait plusieurs conflits shift/reduce (corrigé dans les dernières versions).
- Un mot peut être un mot clé ou pas selon l'endroit où il parait. Il est donc difficile de séparer les analyses lexicales et syntaxiques.
- Possibilité de faire interpréter une chaîne de caractères comme une commande de la shell (commande `eval`).

Bash : analyse syntaxique à la volée

```
#!/bin/bash
# les deux premières lignes sont exécutées avant
# que l'erreur de syntaxe est detectée.

echo "hello"
echo "bonjour"
if fi
```

Bash : si un mot est un mot clef dépend du contexte

```
#!/bin/bash

for do in for do in echo done; do echo $do; done
```

- le premier do est le nom d'une variable
- le deuxième do est une valeur du type string
- le troisième do est un mot clef

Bash : eval

```
#!/bin/bash
# évaluation d'une chaîne construite pendant
# l'exécution du programme.

i=10

mot="if␣((␣i␣>␣0␣));␣then␣echo␣'if ';␣((i--));␣fi"
eval $mot

mot=$(sed -e 's/if/while/g' -e 's/then/do/' \
          -e 's/fi/done/' <<< $mot)
eval "$mot"
```

Conclusion sur la syntaxe de Bash

- Le langage n'était pas conçu pour permettre une analyse syntaxique avant l'exécution.
- Il y a des comportements difficilement prévisibles statiquement (c-a-d avant l'exécution) dû à la nature dynamique du langage.
- Cela rend des scripts Bash difficiles à analyser (par exemple pour détecter des problèmes de sécurité).

Le format JSON

- **J**ava**S**cript **O**bject **N**otation
- Valeurs de base : `true`, `false`, `null`, valeurs numériques, et chaînes de caractères entre guillemets `"`
- Deux mécanismes pour combiner des valeurs :
  - *array* : c'est simplement une liste de valeurs entre crochet `[` et `]`, séparées par des virgules `,`.
  - *object* : c'est une séquence de paires, chacune consistant en une chaîne de caractères et une valeur séparées par `:`. La séquence est notée entre accolades `{` et `}`, les paires sont séparées par des virgules `,`.
- Attention à la différence entre *terminé* et *séparé* par des virgules.

Exemple

```
{
   "menu": {
      "id": "file",
      "value": "File",
      "popup": {
         "menuitem": [
            { "value": "New", "onclick": "CreateNewDoc()" },
            { "value": "Open", "onclick": "OpenDoc()" },
            { "value": "Close", "onclick": "CloseDoc()" }
         ]
      }
   }
}
```

Source : `http://fr.wikipedia.org/wiki/JavaScript_Object_Notation`

La définition officielle

- On trouve sur le "site officiel" de JSON, `http://json.org/`, une série de diagrammes de syntaxe.
- Il y a aussi une proposition de standardisation de la part de la IETF (Internet Engineering Task Force) "RFC7159", disponible à l'adresse `http://tools.ietf.org/html/rfc7159`.

Diagrammes de syntaxe

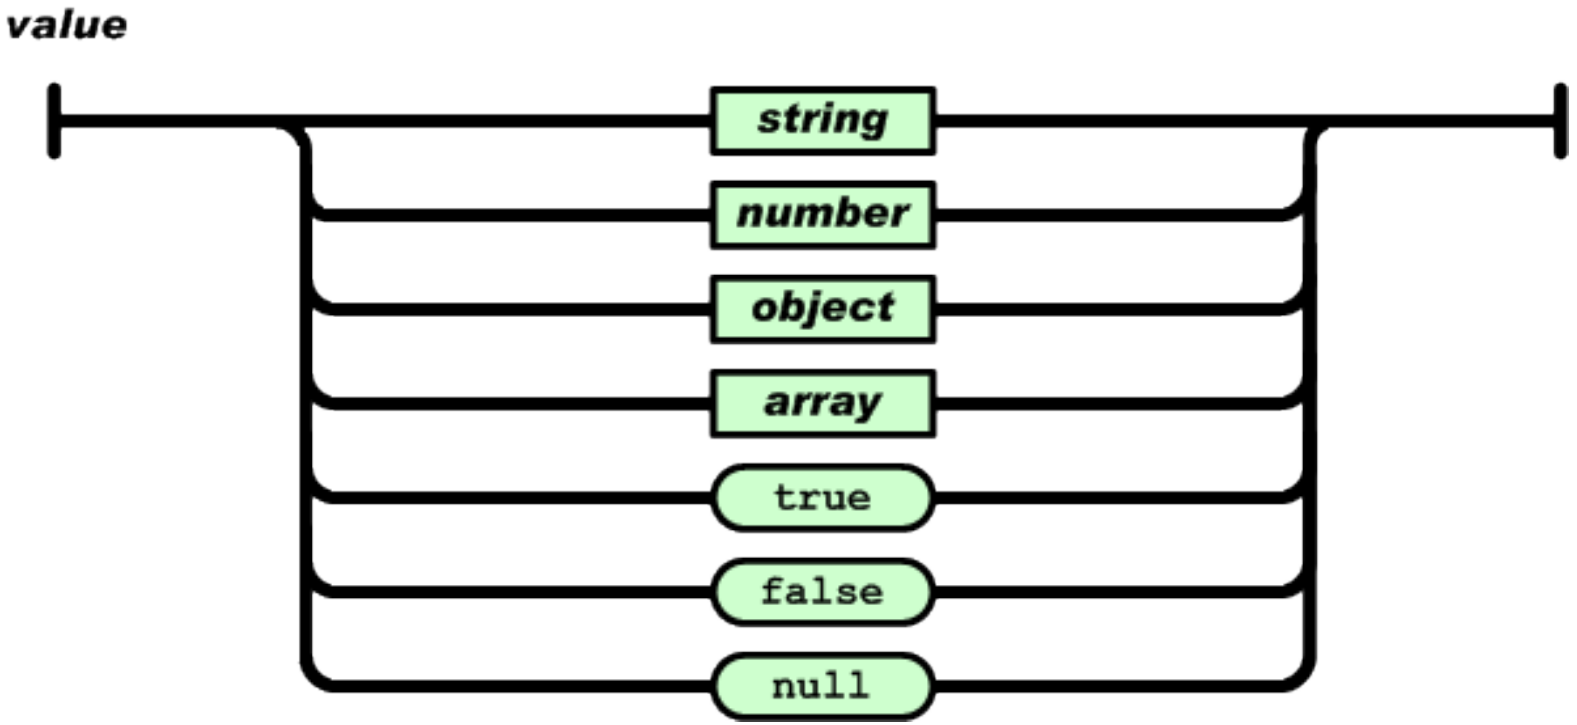

Source : http://json.org/

Diagrammes de syntaxe

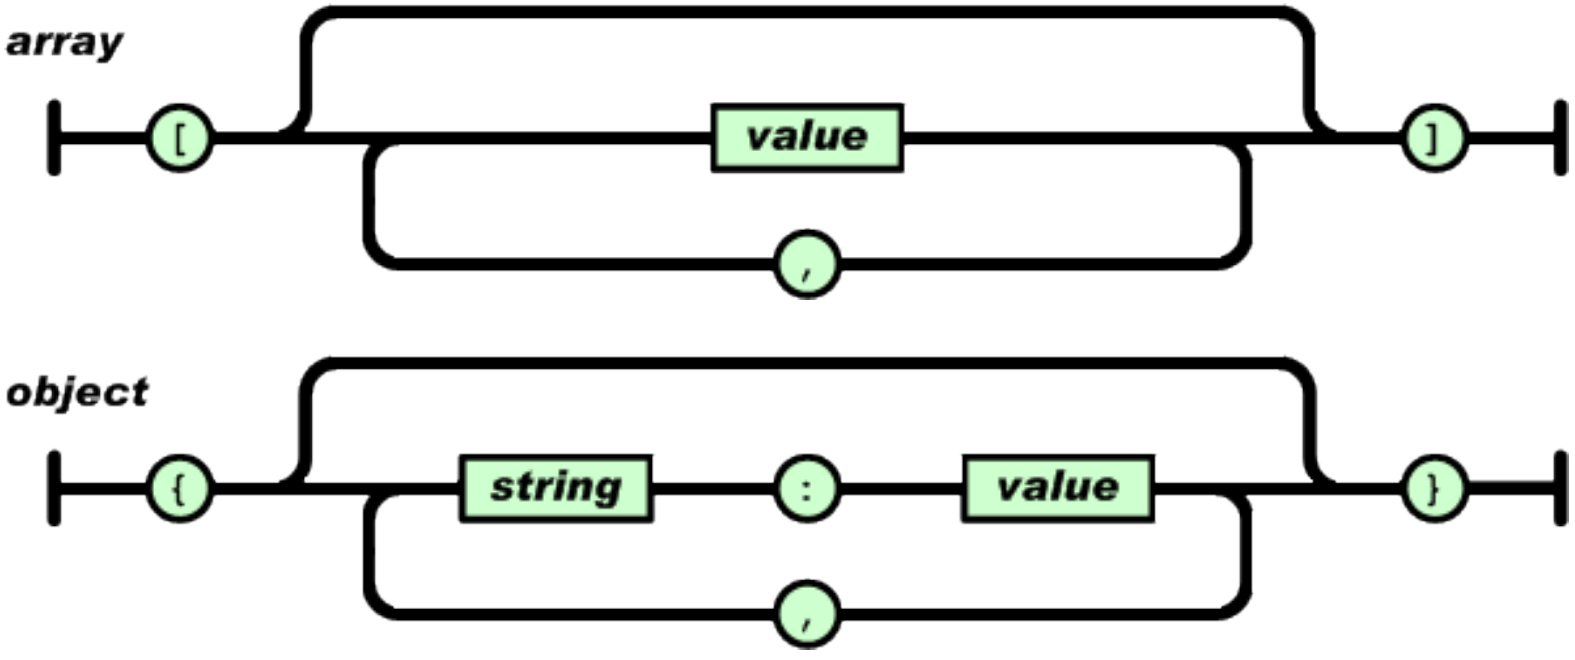

Source : `http://json.org/`

Comment faire analyse lexicale/syntaxique ?

- Expressions régulières pour les chaînes et les valeurs numériques.
- Jetons (délivrés par l'analyse lexicale) :
  - `string`, `number`, (munis de valeurs)
  - `true`, `false`, `null`,
  - `,` , `:`, `{`, `}`, `[`, `]`

La grammaire

- Axiome : Value
- Règles :

$$
\begin{array}{rcl}
\text{Value} & \rightarrow & \texttt{string} \mid \texttt{number} \mid \text{Object} \mid \text{Array} \mid \texttt{true} \mid \texttt{false} \mid \texttt{nul} \\
\text{Array} & \rightarrow & \texttt{[}\ \text{Aseq}\ \texttt{]} \\
\text{Aseq} & \rightarrow & \epsilon \mid \text{AseqNV} \\
\text{AseqNV} & \rightarrow & \text{Value} \mid \text{Value}\ \texttt{,}\ \text{AseqNV} \\
\text{Object} & \rightarrow & \texttt{\{}\ \text{Oseq}\ \texttt{\}} \\
\text{Oseq} & \rightarrow & \epsilon \mid \text{OseqNV} \\
\text{OseqNV} & \rightarrow & \texttt{string :}\ \text{Value} \mid \texttt{string :}\ \text{Value}\ \texttt{,}\ \text{OseqNV}
\end{array}
$$

- Cette grammaire est LR(1) (voir le codage en menhir)

Le format XML

- **E**xtensibe **M**arkup **L**anguage
  (fr. : *langage de balisage extensible*)
- Balise : lexème (un mot, un symbole) qui indique la structure dans un document. Par exemple des parenthèses.
- Objectif : un langage simple et universel pour l'échange de données structurées, à la fois lisible pour des humains et des machines.
- On peut critiquer que le langage est trop verbeux pour les humains, et plutôt conçu pour un traitement automatique.
- Il s'agit d'une instance d'un format plus général, du nom SGML (**S**tandard **G**eneralized **M**arkup **L**anguage).
- Le langage XML est standardisé par le W3C (World Wide Web. Consortium).

La structure d'un document XML

- Un document XML décrit un arbre.
- Un nœud peut avoir un nombre arbitraire (0 inclus) d'enfants.
- Un nœud peut aussi avoir des *attributs*.
- Les enfants d'un nœud sont appelés ses *éléments* ; un élément peut être un morceau de texte, ou un autre nœud.

Exemple

```
<menu id="file" value="File">
  <popup>
    <menuitem value="New" onclick="CreateNewDoc()">
    </menuitem>
    <menuitem value="Open" onclick="OpenDoc()">
    </menuitem>
    <menuitem value="Close" onclick="CloseDoc()">
    </menuitem>
  </popup>
</menu>
```

(sans utiliser le raccourci pour les nœuds sans enfants)

Remarques

- Ça ressemble à du HTML, et pour cause : XML et HTML sont tous les deux des dérivés du langage plus général SGML.
- L'utilisation des chevrons $<$ et $>$ et assez caractéristique pour ces langages.
- Le XML est plus stricte que le HTML, par exemple :
  - XML exige que les valeurs des attributs sont écrites entre guillemets, contrairement aux premières versions de HTML.
  - XML exige que toutes les balises sont proprement fermées, contrairement à HTML qui est très libéral en ce regard.

Vers une définition de la syntaxe

- Un nœud commence avec une balise (angl. : *tag*) de la forme

  $$<m>$$

  et se termine avec

  $$</m>$$

  m est un mot quelconque, appelé le *nom* de cet élément.
- Le nom est obligatoirement le même dans la balise de début et de fin du même nœud. Il est permis d'utiliser le même nom pour plusieurs nœuds du même arbre.
- Une balise de début peut en plus contenir des paires d'attributs avec leurs valeur.

Vers une définition de la syntaxe

- Une paire attribut/valeur est donnée dans la forme

  attr=valeur

  où *attr* est un mot (appelé l'attribut), et *valeur* est une chaîne de caractères entre guillemets (appelée la valeur).
- Il n'est pas permis définir dans la même balise deux fois le même attribut.

Exemple : Données OpenStreetMap

```
<?xml version="1.0" encoding="UTF-8"?>
<osm version="0.6"
     copyright="OpenStreetMap and contributors"
     license="http://opendatacommons.org/licenses/odbl/1-0/">
  <way id="62378611"
       visible="true" version="8" changeset="20691652"
       timestamp="2014-02-21T11:23:38Z" user="thibdrev" uid="1279506">
    <nd ref="779143878"/>
    <nd ref="2198721646"/>
    <nd ref="2198721727"/>
    ........
    <tag k="amenity" v="university"/>
    <tag k="building" v="yes"/>
    <tag k="name" v="Halle aux Farines (Université Paris Diderot)"/>
    <tag k="source" v="cadastre-dgi-fr source : Direction Générale des
    <tag k="wheelchair" v="yes"/>
    <tag k="wikipedia" v="fr:Université Paris VII - Diderot"/>
  </way>
</osm>
```

Une grammaire pour XML ?

- Terminaux (jetons) : `mot`, `string`, `texte`, `/`, `=`, `<`, `>`, `</`
- Non-terminaux : Arbre, Start, End, Attrbs, Elements
- Axiome : Arbre
- Règles :

$$
\begin{aligned}
\text{Arbre} &\rightarrow \text{Start Elements End} \\
\text{Start} &\rightarrow \texttt{<}\ \texttt{mot}\ \text{Attrbs}\ \texttt{>} \\
\text{End} &\rightarrow \texttt{</}\ \texttt{mot}\ \texttt{>} \\
\text{Attrbs} &\rightarrow \epsilon \mid \texttt{mot}\ \texttt{=}\ \texttt{string}\ \text{Attrbs} \\
\text{Elements} &\rightarrow \epsilon \mid \text{Arbre Elements} \mid \texttt{texte}\ \text{Elements}
\end{aligned}
$$

Une grammaire pour XML ?

- Attention : Cette grammaire ne définit pas complètement le langage XML.
- Il y a deux éléments de la définition qui ne sont pas exprimés par la grammaire :
  - Toute balise de début doit être fermée par une balise de fin *du même nom*.
  - Tous les attributs dans une balise de début doivent être *différents*.
- Ces deux restrictions ne peuvent pas être réalisées dans la grammaire, à cause du lemme d'itération.

Validation du XML

- Il est inévitable que la grammaire définit seulement une *sur-approximation* du langage XML.
- Il nous faut une étape supplémentaire de validation qui vérifie les deux restrictions supplémentaires : l'analyse *sémantique*.
- Au moins on peut construire un arbre de syntaxe abstraite sans vérifier les balises, et faire l'étape de vérication des balises sur l'arbre de syntaxe abstraite.
- On rencontre le même problème dans les langages de programmation : toute variable doit être déclarée avant son utilisation.

Le format YAML

- YAML : **Y**aml **A**in't **M**arkup **L**anguage (YAML n'est pas un langage de balisage)
- JSON et XML utilisent des balises pour indiquer la structure du document.
- YAML est un format assez riche, un document YAML peut même contenir des morceaux de JSON.
- Nous regardons ici un seul aspect de YAML : l'utilisation de l'incrémentation des lignes pour indiquer une structure (similaire au langage de programmation *Python*).

Un fragment de YAML

- Nous nous intéressons au fragment de YAML qui permet de définir des arborescences.
- On souhaite représenter par un document en YAML un arbre dont les arêtes sont étiquetées par des chaînes de caractères, et dont les feuilles portent des chaînes de caractères.
- Contrainte supplémentaires : toutes les arêtes partant du même nœud portent des étiquettes différentes.

Exemple d'un document YAML

```
invoice  : 34843
date     : 2001-01-23
customer :
    first  : Chris
    last : Dumars
    address:
        city    : Royal Oak
        state   : MI
        postal  : 48046
```

Représentation sous forme d'un arbre

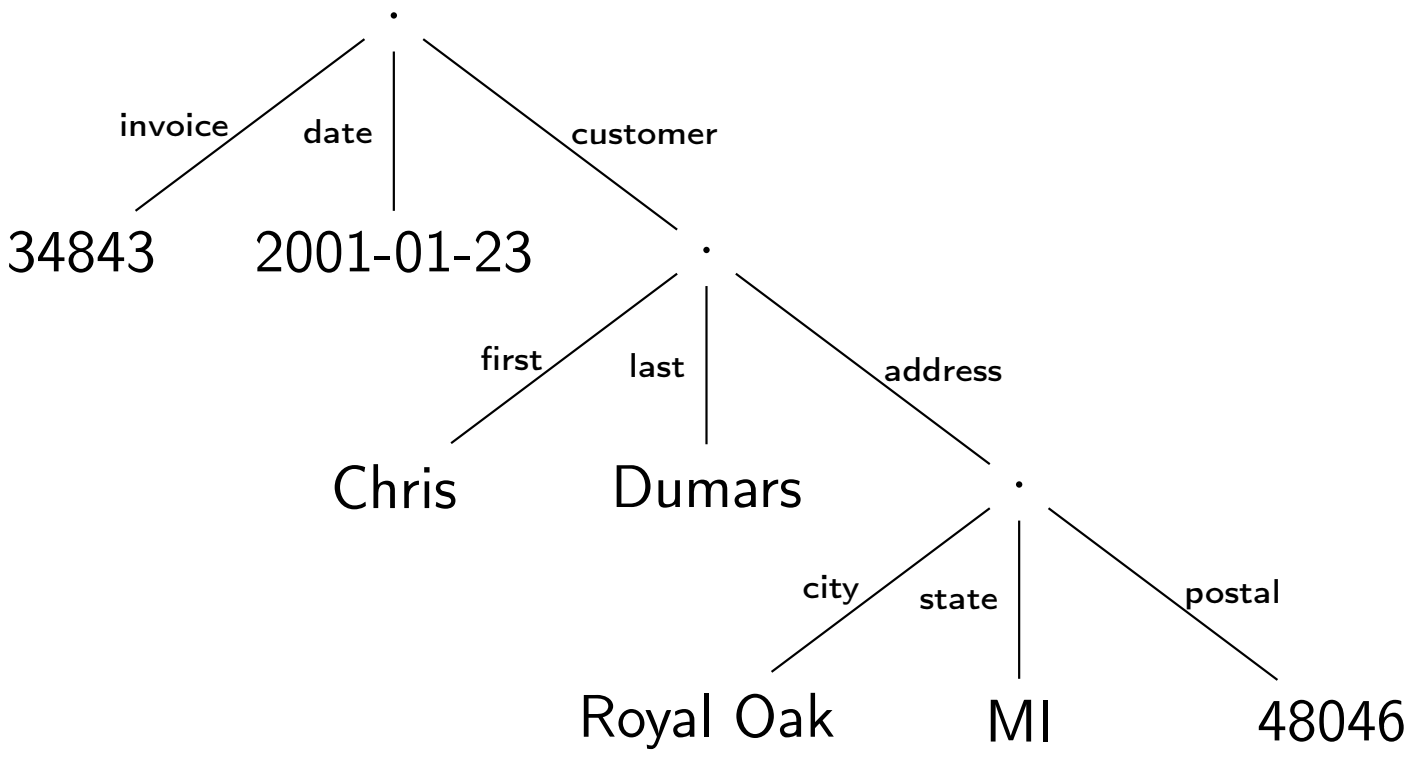

Comment lire un tel document YAML

- Une ligne peut contenir une paire clef – valeur.
- Une ligne peut aussi contenir seulement une clef, dans ce cas une sous-structure doit suivre à partir de la ligne suivante.
- L'incrémentation des lignes indique le début ou la fin d'une sous-structure.

Comment faire l'analyse syntaxique ?

- Premier problème : il faut assurer que les clefs sont différentes pour chaque nœud dans l'arborescence.
- Problème assez similaire à la vérification des balises dans un document XML : on peut d'abord construire l'arbre, et puis faire cette vérification sur l'arbre construit.
- Deuxième problème : comment analyser les différences dans l'incrémentation des lignes, qui jouent ici le rôle de parenthèses ?
- On aura le même problème avec le langage Python, voir plus tard !

Java et OCaml

- Les langages de programmation “modernes” (JAVA, OCaml, etc.) sont normalement LR(1) ou même LALR(1). Les compilateurs sont presque toujours construits à l'aide des générateurs d'analyse syntaxique, du type Lex et YACC/Menhir.
- L'exception la plus importante est probablement Python (voir plus tard).
- Il y a souvent des ambiguïtés du type “dangling else” qui peuvent être résolus grâce à des priorités (voir le cours sur Menhir)
- Un problème similaire existe en OCaml avec des “match” imbriqués (voir le transparent suivant)

OCaml : absence de mots terminateurs

```
type t = A of t | B of t | C of t | I of int

let f x = match x with
  | A y -> true
  | B y -> match y with
           | A z -> false
           | B z -> true
           | C z -> false
           | I n -> true
  | C y -> false
  | I n -> true
```

- On s'aperçoit de Warnings quand on compile ce code.
- En fait, les deux dernières lignes sont comprises par le compilateur comme faisant partie du deuxième match.
- On est donc obligé de mettre des *begin* et *end* pour expliciter la structure.
- Ceci est dû à une décision discutable des concepteur du langage OCaml de ne pas avoir des mots clefs qui terminent certaines instructions composées (if, match).

L'exemple rectifié

```
type t = A of t | B of t | C of t | I of int

let f x = match x with
  | A y -> true
  | B y -> begin
      match y with
        | A z -> false
        | B z -> true
        | C z -> false
        | I n -> true
    end
  | C y -> false
  | I n -> true
```

Python

- Analyse syntaxique complète avant exécution.
- Syntaxe : la structure du programme est indiquée par le niveau d'*incrémentation* des lignes.
- Par conséquent, Python n'est pas un langage algébrique, sa syntaxe ne peut pas être définie par des expressions rationnelles et des grammaires algébriques.

Python : analyse syntaxique complète

```
#!/usr/bin/python3
# erreur de syntaxe detectee avant execution

print("hello")
print("bonjour")
if fi
```

Syntaxe de Python

```
if x < 0:
    x = x-1
else:
    x = x+1
    x = x*x
```

a une *structure différente* de

```
if x < 0:
    x = x-1
else:
    x = x+1
x = x*x
```

Erreur : changement de l'incrémentation dans le même bloc

```
#!/usr/bin/python3

if␣x␣>␣42␣:
␣␣␣␣print(x)
␣␣␣␣␣␣print(x+x)
␣␣␣␣print(x*x
```

Erreur : retour à un niveau d'incrémentation inconnu

```
#!/usr/bin/python3

print(32)
if␣x␣>␣17␣:
␣␣␣␣print(x)
␣␣␣␣if␣x␣>␣42␣:
␣␣␣␣␣␣␣␣print(x+x)
␣print(x*x)
```

Comment reconnaître les niveaux d'incrémentation ?

- Idée : utiliser des jetons `OPEN` et `CLOSE`, envoyés par l'analyse lexicale quand l'incrémentation change.
- L'analyse lexicale maintient une *pile* de niveaux d'incrémentation actuellement actives, initialisée à une valeur 0.
- Quand l'analyse lexicale trouve une incrémentation de ligne augmentée : envoie le jeton `OPEN`, empile la nouvelle valeur.
- Quand l'analyse lexicale trouve une incrémentation de ligne réduite : envoie le jeton `CLOSE`, supprime la valeur de la pile.
- Il y a un problème dans le dernier cas ...

Problème avec la fermeture d'un niveau

```
#!/usr/bin/python3

x=42
if␣x␣>␣1␣:
␣␣␣␣print("niveau␣1")
␣␣␣␣if␣x␣>␣10␣:
␣␣␣␣␣␣␣␣print("niveau␣2")
print("niveau␣0")
```

On peut fermer plusieurs niveaux sur un seul coup !

Solution

- Quand plusieurs niveaux sont fermés : il faut en principe envoyer plusieurs jetons `CLOSE` à la fois !
- Or, on attend de l'analyse lexicale un seul jeton à la fois.
- Solution : L'analyse lexicale maintient un compteur pour les fermetures de niveaux qui restent à communiquer.
- Voir le code dans le répertoire `mini-python` pour les détails.

Conclusion sur l'analyse syntaxique de Python (et YAML)

- On peut parfois faire une analyse syntaxique à l'aide de Lex et Menhir aussi dans des cas où le langage n'est pas algébrique !
- La raison est qu'il y a des morceaux de code dans les actions des fichiers Lex et Menhir. Dans ces morceaux de code, on peut faire des tests supplémentaires.

Bash : typage et évaluation

- Typage dynamique : bash ne construit pas d'arbre de syntaxe abstraite avant l'exécution, il n'y a donc aucun moyen pour analyser statiquement le typage.
- Il n'y a pas de types, les valeurs des variables sont des chaînes caractères.
- Il y a une syntaxe distincte pour les expressions arithmétiques.
- Si on veut des listes on les encode dans des string, avec les éléments séparés par des espaces, ce qui est une source riche de bugs.
- Modèle d'exécution bizarre qui confond les booléens avec la présence/absence d'erreurs d'exécution.

Typage dynamique

- Typage dynamique : vérification des types pendant l'*exécution* du programme, quand on applique un opérateur à des valeurs.
- Avantage : plus de flexibilité (mais : flexibilité aussi possible dans le cas statique, par ex. polymorphie).
- Avantage : programmes moins verbeux, car il n'est pas nécessaire de déclarer les variables avec leur type (mais : le même avantage peut être obtenu par une *inférence de type*).
- Inconvénient : l'interpréteur doit garder *pendant l'exécution* l'information de type de toutes les valeurs.
- Inconvénient : les erreurs de typage sont découvertes pendant l'exécution.
- Exemples : Python, Perl.

Python : typage dynamique

```
#!/usr/bin/python3
# la meme variable peut prendre des valeurs de
# type different.

x=42
print(x)
x=True
print(x)
```

Python : typage dynamique

```
#!/usr/bin/python3
# erreur de typage seulement detectee quand
# la branche else est executee

import sys
while True:
    read=sys.stdin.readline()
    if read != 'coocoo\n':
        print(17+21)
    else:
        print ('abc' & 'def')
```

Typage statique

- Typage statique : vérification des types après construction de la syntaxe abstraite, et *avant* l'exécution.
- Avantage : Sûreté. Une fois le typage vérifié par le compilateur on sait que des erreurs de *type* ne peuvent plus se produire (sauf dans certains langages de programmations qui permettent de contourner le typage).
- Avantage : Le compilateur peut annoter la syntaxe abstraite par des types des expressions, ce qui simplifie l'exécution. Désambiguïsation des opérateurs surchargés.
- Exemples : Java, OCaml, ...

Java

- Construction de la syntaxe abstraite par le compilateur.
- Typage statique.
- L'information de typage doit être écrite explicitement dans le programme.
- Vérification statique (donc, par le compilateur) des exceptions.
- Inconvénient : les programmes sont verbeux.

OCaml

- Typage statique.
- *Inférence* de type : le compilateur infère les types des identificateurs, il n'est pas nécessaire de les écrire dans le programme.
- On peut écrire dans le programme les types des identificateurs si on le souhaite.
- Avantage : programmes concis, et en même temps sûreté de typage.
- Incovénient : l'inférence de type limite les possibilités de surcharge des opérateurs.
- Syntaxe critiquable pour l'absence de mots clef qui terminent des expressions complexes.