Grammaires et Analyse Syntaxique - Cours 1 Introduction et Rappels

Ralf Treinen

Université Paris Cité

INSTITUT DE RECHERCHE EN INFORMATIQUE FONDAMENTALE

treinen@irif.fr

25 janvier 2024

Organisation

- 12 cours d'amphi
- 12 séances de TP/TD. Première séance de TP/TD : semaine du 29/1.
- Chaque semaine soit une séance TD, soit séance TP (sur le même créneau d'horaire).
- Page web (transparents du cours, calendriers, ...)

  `http://www.irif.fr/~treinen/teaching/gas6/`
- Page moodle (pour les TP/TD) :

  `https://moodle.u-paris.fr/course/view.php?id=1643`

  Inscrivez-vous sur moodle pour votre groupe de TD !

Contrôle de connaissances

- Examen écrit
- Un contrôle TD
- Un projet de programmation
- $$session1 = 20\%\text{TD} + 30\%\text{projet} + 50\%examen1$$
- $$session2 = max(examen2, 20\%\text{TD}+30\%\text{projet}+50\%examen2)$$

Pré-requis

1. *Automates et Analyse Lexicale* du L2 (il y aura des rappels de l'essentiel)
   - expressions rationnelles (comprendre le sens d'une expression rationnelle, écrire des expressions rationnelles dans des cas simples)
   - automates finis déterministes, non-déterministes et avec epsilon-transitions, élimination des epsilon-transitions, algorithme de déterminisation
   - limitation des automates et expressions rationnelles, en particulier le lemme d'itération (pumping lemma)
   - utilisation d'un générateur d'analyse lexicale du type LEX
2. *Programmation Fonctionnelle* (langage OCaml) du L3

Qu'est-ce que c'est ce cours ?

- Qu'est-ce que c'est une *grammaire* ?
- Qu'est-ce que c'est, l'*analyse syntaxique* ?
- C'est pour analyser quoi ?
- Qu'est-ce qu'on obtient par l'analyse ?
- Quoi faire avec le résultat de cette analyse ?

Grammaires

- Souvent utilisées pour définir des langages *structurés*.
- Les *expressions rationnelles* (voir cours AAL3) sont déjà un outil pour définir des langages, mais elles ne permettent pas d'exprimer des *structures imbriquées* intéressantes.
- Extrait simplifié d'une grammaire (du manuel OCaml) :

$$\begin{array}{rcl} \textit{expr} & ::= & \textit{constant} \\ & | & \texttt{(}\ \textit{expr}\ \texttt{)} \\ & | & \textit{expr}\quad \textit{operator}\quad \textit{expr} \end{array}$$

  définit le langage des expressions *parenthésées*.
- On peut définir ce qu'est *constant* et *operator* par des expressions rationnelles.
- Nous allons utiliser une notation un peu plus "matheuse" pour les grammaires (cours 3)

Analyse Syntaxique

- Elle va d'abord nous dire, pour une grammaire donnée, si un texte d'entrée correspond à la grammaire ou pas.
- Exemple :

$$\begin{array}{rcl} \textit{expr} & ::= & \textit{constant} \\ & | & \texttt{(}\ \textit{expr}\ \texttt{)} \\ & | & \textit{expr}\quad \textit{operator}\quad \textit{expr} \end{array}$$

- `( ( 17 + 4 ) * 42 )` est correct
- `( + 5` n'est pas correct
- Plus important : quand le texte est correct, l'analyse syntaxique va nous indiquer la *structure* du texte !
- Il s'agit donc de la *découverte de la structure* dans un texte, selon une grammaire donnée.

C'est pour analyser quoi ?

- Des textes, par exemple le contenu d'un fichier, qui est censé correspondre à une certaine grammaire
- Exemple (le plus important pour nous) : des programmes qui doivent correspondre à une grammaire pour OCaml, Java, ...
- Exemple : des langages de données : XML, Yaml, JSON, ...
- De toute façon il s'agit (dans ce cours) toujours de langages *artificiels* définis par des informaticiens, grâce aux grammaires.
- L'analyse des langues *naturelles* est beaucoup plus complexe, et un sujet important de la *Linguistique*.

Qu'est-ce qu'on obtient de l'analyse ?

- Si l'entrée n'est pas acceptée : un message d'erreur (si possible avec une indication utile de l'erreur)
- Si l'entrée est correcte : une représentation de la structure trouvée dans le texte.
- Par exemple pour les expressions parenthésées, on peut utiliser les type OCaml suivant :

```
type constant = int
type operator = Plus | Mult
type expr = Const of constant
          | Paren of expr
          | Infix of expr * operator * expr
```

- On parle d'un *arbre de syntaxe*

Exemple : expressions parenthésées

- Entrée : `( 17 + 4 )`
- La valeur retournée par l'analyse (du type expr) :

  `Paren(Infix(Const(17), Plus, Const(4)))`

- Structure d'arbre :

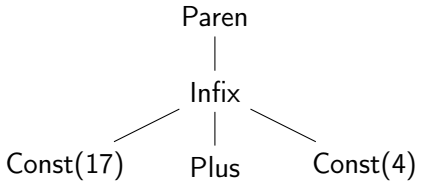

Quoi faire avec le résultat de l'analyse ?

Ce qu'il faut faire avec l'arbre de syntaxe dépend de l'application :

- Programmes : analyser (vérifier les types, par ex.), optimiser, engendrer du code exécutable.
  C'est la *Compilation* (→ Cours du M1)
- Des données : différents traitements possibles, par exemple création d'un rendu graphique.

Le rôle de l'analyse

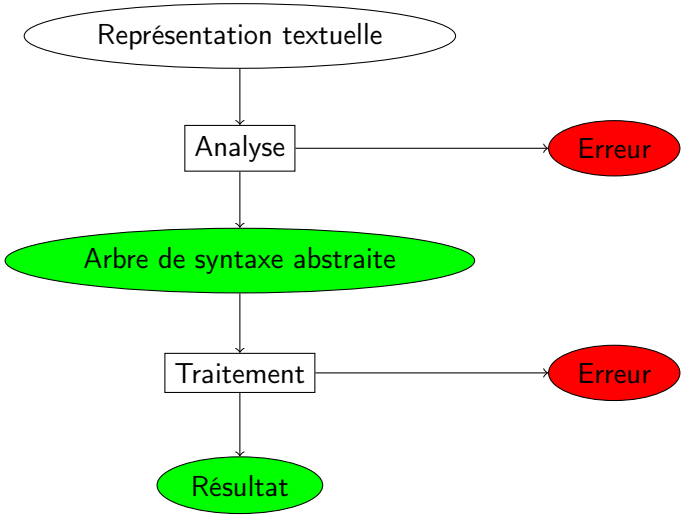

Exemple : Un morceau d'un programme

```
while b != 0
    if a > b
        a := a - b
    else
        b := b - a
return a
```

Donné en entrée à l'analyse.

Arbre de syntaxe (abstraite)

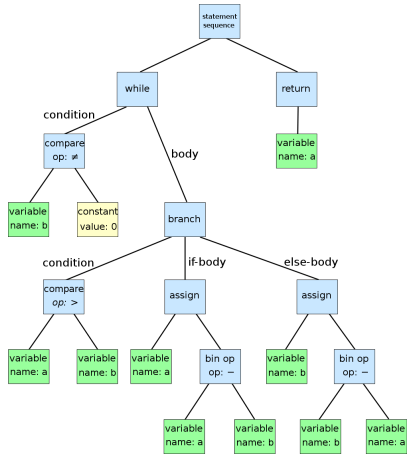

Résultat de l'analyse syntaxique.

Document HTML (écrit à la main)

```
<!DOCTYPE HTML PUBLIC "-//W3C//DTD HTML 4.01 Transitional//EN">
<html>
<head>
  <meta http-equiv="Content-Type" content="text/html; charset=utf8">
  <title>Programmation Fonctionnelle Avancée</title>
</head>

<body>

<center>
<h1>M1 2014/2014 :  Programmation Fonctionnelle Avancée</h1>
<a href="http://www.univ-paris-diderot.fr">Université Paris-Diderot</a>,
<a href="http://www.informatique.univ-paris-diderot.fr">UFR d'Informatique</a>

</center>

<h2><a name=salle>Salle et Horaires</a></h2>
Cours : Jeudi, 15h30-17h30, salle 247E, Halle aux Farines.
Premier cours: jeudi 18 septembre.
<p>
```


Document HTML : rendu par firefox

M1 2014/2014 : Programmation Fonctionnelle Avancée

Université Paris-Diderot, UFR d'Informatique

Salle et Horaires

Cours : Jeudi, 15h30-17h30, salle 247E, Halle aux Farines. Premier cours: jeudi 18 septembre.

TD/TP : Mercredi, 13h30-15h30, salle 2032, bâtiment *Sophie Germain* Premier TD/TP: le mercredi 24 septembre.

Projet

Voir la page du projet.

Examen

Jeudi, 15 janvier 2015, 12h30-15h30, amphi 5C, Halle aux Farines.

[Planning des examens M1 premier semestre]

Contenu du cours

La programmation fonctionnelle est née presque en même temps que la programmation impérative, avec le langage Lisp à la fin des années 1950. Utilisé paradigme de programmation privilégié dans les années 1970 à 1990 pour l'Intelligence Artificielle, elle demandait des machines puissantes et chères, et

Document XML : 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 Impôts - Cadas
    <tag k="wheelchair" v="yes"/>
    <tag k="wikipedia" v="fr:Université Paris VII - Diderot"/>
  </way>
</osm>
```


Document XML : rendu par OpenStreetMap

Ce qu'on va apprendre dans ce cours

- Comprendre et écrire des grammaires
- Plusieurs approches à l'analyse syntaxique
- Utilisation d'un générateur d'analyseurs syntaxiques
- Réaliser la première partie d'un compilateur, en utilisant :
  - un générateur d'analyse lexicale (ocamllex)
  - un générateur d'analyse grammaticale (menhir)
  - un peu de programmation en OCaml
- Les propriétés des *langages algébriques*, les *automates à pile*, et leur relation avec les langages réguliers et les automates finis.

Démarche

- La tâche n'est pas triviale : le programme doit reconnaître la *structure* dans un texte, et générer une représentation de cette structure.
- Découpage de l'analyse en deux phases : *analyse lexicale* et *analyse grammaticale*.
- La première phase utilise les *expressions rationnelles* vues dans le cours *Automates et Analyse Lexicale*.
- La deuxième phase est le sujet principal de ce cours.

Un autre problème : *Séquentialisation*

- Opération dans l'autre sens : traduire une représentation machine (arbre de syntaxe) en texte.
- On pourrait s'attendre à ce que les deux opérations soient l'inverse l'une de l'autre mais ce n'est pas forcément le cas.
- Exemple : un compilateur de programme peut simplement ignorer les commentaires dans le programme.
- L'opération de séquentialisation est beaucoup plus simple à mettre en œuvre que l'opération d'analyse.

Les expressions rationnelles

- Synonymes : expressions rationnelles, expressions régulières
- Une expression rationnelle définit un ensemble de mots (aussi appelé *un langage*).
- Elles sont d'abord utilisées dans la *définition* de la syntaxe des langages informatiques (langages de programmation, langages de données).
- Exemple : les règles de Java pour l'écriture du nom d'une variable, d'une valeur entière, d'une valeur flottante, d'une chaîne de caractères.
- Il faut comprendre ces règles pour savoir écrire correctement un document, mais aussi pour savoir lire (et pour écrire un programme qui sait analyser un document).

Définition des expressions rationnelles

- Donnée : un alphabet Σ, c.-à-d. un ensemble fini de symboles
- On définit d'abord la *syntaxe* des expressions rationnelles : Définition *inductive* de l'ensemble Rat.
- Puis on définit une *sémantique*, à l'aide d'une fonction *récursive* $\mathcal{L}(\cdot)$: Rat $\to P(\Sigma^*)$.
- La sémantique associe à chaque expression rationnelle un ensemble de mots sur l'alphabet Σ.

Syntaxe des Expressions Rationnelles

Définition inductive de l'ensemble Rat, étant donné un alphabet Σ :

- $\emptyset \in$ Rat
- Pour tout symbole $a \in \Sigma$: $a \in$ Rat
- $\epsilon \in$ Rat.
- Si $r_1, r_2 \in$ Rat, alors $r_1 r_2 \in$ Rat
- Si $r_1, r_2 \in$ Rat, alors $r_1 \mid r_2 \in$ Rat
- Si $r \in$ Rat, alors $(r) \in$ Rat
- Si $r \in$ Rat, alors $r^* \in$ Rat
- C'est tout.

ATTENTION

- Nous écrivons | pour l'union, pas + comme c'était fait dans le cours *Automates et Analyse Lexicale du S3*.
- Raison : c'est la convention utilisée par presque tous les outils informatiques qui travaillent avec les expressions rationnelles, et en particulier par lex dans toutes ses variantes.

Sémantique des Expressions Rationnelles

- $\mathcal{L}(\emptyset) = \emptyset$
- $\mathcal{L}(a) = \{a\}$ pour tout $a \in \Sigma$
- $\mathcal{L}(\epsilon) = \{\epsilon\}$
- $\mathcal{L}(r_1 r_2) = \{w_1 w_2 \mid w_1 \in \mathcal{L}(r_1), w_2 \in \mathcal{L}(r_2)\}$
- $\mathcal{L}(r_1 \mid r_2) = \mathcal{L}(r_1) \cup \mathcal{L}(r_2)$
- $\mathcal{L}((r)) = \mathcal{L}(r)$
- $\mathcal{L}(r^*) = \{w_1 \cdots w_n \mid n \geq 0, w_i \in \mathcal{L}(r)\}$

Exemples d'expressions rationnelles

- Nous choisissons pour l'exemple $\Sigma = \{\mathtt{a}, \mathtt{b}, \mathtt{c}, \mathtt{d}\}$
- $\mathcal{L}(\mathtt{abc} \mid \mathtt{bcd}) = \{\mathtt{abc}, \mathtt{bcd}\}$
- $\mathcal{L}(\mathtt{aa}(\mathtt{b} \mid \mathtt{c})\mathtt{dd}) = \{\mathtt{aabdd}, \mathtt{aacdd}\}$
- $\mathcal{L}((\mathtt{a} \mid \mathtt{b} \mid \mathtt{c} \mid \mathtt{d})*)$: l'ensemble de tous les mots sur Σ
- $\mathcal{L}((\mathtt{a} \mid \mathtt{c})*)$: l'ensemble de tous le mots formés des lettres a et c seulement
- $\mathcal{L}((\mathtt{aa})*)$: l'ensemble de toutes les séquences de a de longueur paire.

Limites des expressions rationnelles

Il y a des langages qui ne sont pas réguliers, par exemple :

- L'ensemble de tous les mots qui contiennent le même nombre de a que de b
- L'ensemble de tous les palindromes
- L'ensemble de tous les mots dont la longueur est un nombre premier
- L'ensemble des expressions arithmétiques correctement parenthésées

Pourquoi des expressions rationnelles alors ?

- Expressivité limitée, mais ...
- On sait faire plein de choses avec, par exemple :
  - Décider l'appartenance d'un mot au langage
  - Décider vide, universalité
  - Calculer le complément par rapport à Σ^*
  - Calculer l'intersection
  - Traduire en un automate fini

Sucre Syntaxique

Des extensions de syntaxe qui sont pratiques, mais qui n'apportent rien à l'expressivité.

- $r?$: soit le mot vide, soit un mot dans $\mathcal{L}(r)$
  Abréviation pour $\epsilon \mid r$
- $r+$: une séquence *non-vide* de de mots dans $\mathcal{L}(r)$
  Abréviation pour $rr*$
- $r\{n, m\}$ pour $n, m \in \mathbb{N}$: une séquence de i mots dans $\mathcal{L}(r)$, où $n \leq i \leq m$
  Abréviation pour

$$\underbrace{r \cdots r}_{n} \mid \ldots \mid \underbrace{r \cdots r}_{m}$$

Systèmes d'expressions rationnelles

- Il est souvent utile de faire référence à une expression rationnelle déjà définie.
- Exemple :

$$\begin{aligned} r_1 &= (\mathtt{a}|\mathtt{b}) * \mathtt{c} \\ r_2 &= r_1 + \\ r_3 &= r_1 \mathtt{e} r_2 \end{aligned}$$

- C'est simplement un raccourci :

$$\begin{aligned} r_1 &= (\mathtt{a}|\mathtt{b}) * \mathtt{c} \\ r_2 &= ((\mathtt{a}|\mathtt{b}) * \mathtt{c}) + \\ r_3 &= (\mathtt{a}|\mathtt{b}) * \mathtt{ce}((\mathtt{a}|\mathtt{b}) * \mathtt{c}) + \end{aligned}$$

- Attention : les cycles entre définitions d'expressions rationnelles ne sont pas permis !

L'objectif de l'analyse lexicale

- Découper un texte d'entrée en une séquence de *lexèmes*, et les représenter par des *jetons* (*tokens* en anglais)
- À la base : Classification des lexèmes qui peuvent paraître dans un texte d'entrée, à l'aide des expressions régulières.
- La phase suivante de l'analyse (l'analyse grammaticale, voir plus tard) va travailler sur le résultat de ce découpage : il s'agit d'une *abstraction* du texte d'entrée.

Les deux phases de l'analyse

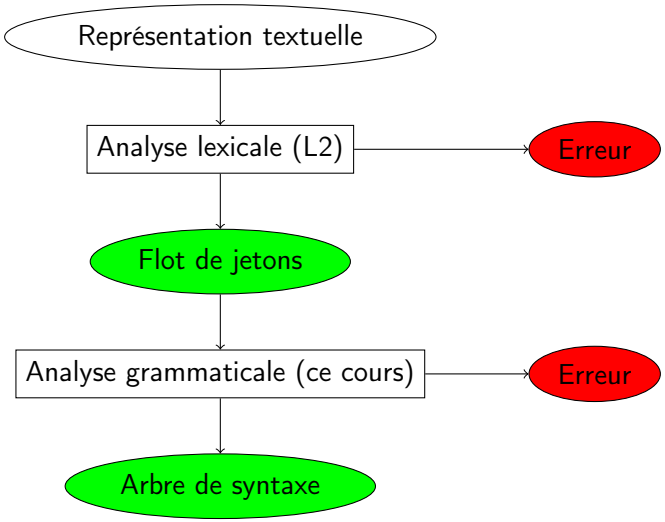

Exemple

- Texte d'entrée :

(	7	5	6	e	2		*		(	e	5	e	7		+		v	a	l	e	u	r	2	)	)

- Résultat de l'analyse lexicale (L2) : jetons
  PARG INT MULT PARG IDENT PLUS IDENT PARD PARD
- Résultat de l'analyse grammaticale (ce cours) : arbre

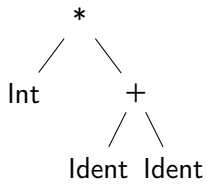

Pourquoi deux étapes séparées ?

- On essaye de faire autant d'analyses que possible dans l'analyse lexicale.
- Raison : l'exécution d'un automate est très efficace (temps linéaire dans la longueur du texte d'entrée).
- Problème : l'expressivité des automates est limitée : théorème de l'étoile, théorème de Myhill-Nerode.
- On verra un cas concret qu'on ne peut pas reconnaître avec les expressions rationnelles la semaine prochaine.

Jetons avec arguments

- En réalité, on veut aussi garder certaines informations avec les jetons, comme la valeur d'une constante entière, ou le nom d'un identificateur.
- Certains jetons doivent donc avoir un argument :
  - IDENT(string)
  - INT(int) (c'est bien `int` et pas `string` !)
- Séquence des jetons obtenue sur l'exemple :
  PARG INT(75600) MULT PARG IDENT("e5e7") PLUS IDENT("valeur2") PARD PARD

Ignorer des informations pas pertinentes

L'analyse lexicale sert aussi à faire abstraction de certaines informations dans le texte d'entrée qui ne sont pas pertinentes pour l'analyse du texte. Souvent il s'agit de :

- Les espaces : sont utiles pour indiquer la fin d'un mot. Les espaces sont utiles *pour* l'analyse lexicale, mais une fois le découpage fait on peut les oublier.
- Les commentaires : souvent l'analyse lexicale vérifie l'écriture correcte des commentaires, mais ne les représente pas dans sa sortie.

Exemple

Différents textes d'entrée qui peuvent donner la même séquence de jetons :

- `34 * (x + y)`
- `34*(x+y)`
- `34     *(     x+   y)`
- `34 * (x+y) /* Ceci est un commentaire */`

Quelle information retenir dans les jetons

- On retient dans les jetons seulement l'information qui est utile pour la suite.
- La distinction entre information utile/inutile dépend de l'application.
- Par exemple : Les commentaires peuvent être utiles à retenir pour certaines applications.
- Il peut être utile de conserver avec les jetons aussi des informations de *localisation* : nom du fichier source, numéro de ligne, numéro de colonne.

Résoudre les ambiguïtés

- L'analyse lexicale va, pour produire le jeton suivant, chercher un *préfixe* du reste du texte qui correspond à une des catégories lexicales, et construire le jeton correspondant.
- Il y a deux sources d'ambiguïtés :
  - Des préfixes de longueurs différentes peuvent être reconnus
  - Les expressions régulières peuvent avoir une intersection non vide

Préfixes de longueur différentes reconnus

Exemple :

- Catégorie lexicale :
  - IDENT : `[a..z]+`
- Début du texte d'entrée :
  `xyz`
- Plusieurs possibilités de découpage :
  1. `IDENT("x") IDENT("y") IDENT("z")`
  2. `IDENT("xy") IDENT("z")`
  3. `IDENT("x") IDENT("yz")`
  4. `IDENT("xyz")`
- La règle normale est : on cherche le préfixe *maximal*. Dans l'exemple ca donne `IDENT("xyz")`.

Plusieurs expressions régulières s'appliquent

Exemple :

- Catégories lexicales :
  - PUBLIC : `public`
  - IDENT : [a..z]+
  - sauter les espaces
- Début du texte d'entrée :
  `public publication`
- Plusieurs possibilités de découpage :
  1. `PUBLIC IDENT("publication")`
  2. `IDENT("public") IDENT("publication")`
- La règle normale est : à longueur égale du mot reconnu, c'est la première expression régulière qui gagne.

Plan du cours