Compilateurs : Analyse lexicale

Matthieu Amiguet

2009 – 2010

haute école arc ingénierie
neuchâtel berne jura | saint-imier le locle delémont

"Vous êtes ici" 2

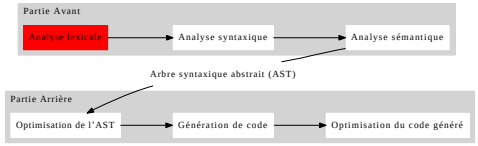

Analyse lexicale 4

- En entrée d'un compilateur, on a généralement un fichier
  - C'est à dire essentiellement une suite de caractères
- La première chose à faire est de regrouper ces caractères pour former des "mots"
  - nombres
  - identificateurs
  - mots réservés
  - ...
- Dans le vocabulaire des compilateurs, ces "mots" s'appellent des *lexèmes* (angl : *token*)
- L'étape d'identification des lexèmes s'appelle *analyse lexicale* (angl : *lexical analysis* ou *scanning*).

Les lexèmes 5

- Qu'est-ce qu'un lexème ? La réponse précise dépend beaucoup du contexte...
- Une bonne ligne de conduite :

  Si un "truc" peut être séparé de ses voisins par des espaces sans changer la signification, c'est un lexème ; sinon pas.
- Ne signifie pas qu'un lexème ne doit pas contenir d'espaces !
  -
- Les commentaires et les espaces ne sont pas des lexèmes : ils sont simplement mis de côté par l'analyseur lexical...
  - ... sauf s'ils sont conservés pour le diagnostic d'erreur, la réflexion, etc.

Plus important qu'il n'y paraît... 6

- Malgré une apparente simplicité, la lecture du code source et l'analyse lexicale prennent beaucoup de temps
  - Jusqu'à 30% du temps de la partie avant !
- Ces deux étapes sont en effet les seules à voir tout le texte du programme
  - Une ligne moyenne fait 30-50 caractères...
  - et ne contient que quelques lexèmes (~5) !
- Il faut donc faire très attention à l'efficacité de leur implémentation !
- Pour un compilateur portable, c'est aussi à ce niveau-là qu'on se "débarrasse" des particularités des plate-formes (fins de lignes, ...).

... et pas si simple ! 7

- Dans certrains cas, l'analyse lexicale est très facile :
  - `102*4-12*3`
- Mais parfois cela peut être bien plus délicat
  - `1e+3+3*pi-2*e-5`
  - `print "Il a dit : \"bonjour !\""`
  - `12.3+math.cos(180)`

Le but du jeu 8

- Pour clarifier le but de l'analyse lexicale :

  Il s'agit non seulement de séparer les lexèmes, mais aussi d'identifier leur type
- Exemple :
  - `12+3` ⇝ `NUMBER(12) OPERATOR(+) NUMBER(1)`
- La question maintenant est de faire ça de manière générique et efficace...

Écriture manuelle d'un analyseur lexical 10

- Il n'est pas très difficile d'écrire un analyseur lexical à la main
  - Un aiguillage sur le premier caractère lu permet souvent de séparer le problèmes en quelques sous-problèmes simples
  - Il ne reste plus qu'à écrire le code pour les sous-problèmes...
- Cette façon de faire est laborieuse, et peu adaptable en cas de changements/adaptations du langage...
- On préfère souvent générer automatiquement un analyseur sur la base de descriptions formelles des lexèmes.

Génération automatique d'un analyseur lexical 11

- Il existe des générateurs de code
  - qui prennent en entrée une description des lexèmes ainsi que quelques informations annexes, et
  - qui produisent en sortie le code d'un analyseur lexical
- Avantages sur la génération à la main
  - Souplesse en cas de changement de description de lexèmes
  - Moins d'erreurs
  - Plus lisible
  - Algorithmes assez fortement optimisés
  - Si la description des lexèmes est assez "standard", elle peut également servir à documenter le langage...
- Le plus connu : Lex et ses variantes (Flex, JLex, ...)
- Le langage de description le plus courant : les *expressions régulières*

Expressions régulières 12

- Les expressions régulières sont un langage qui sert à définir des langages...
- L'idée est la suivante : grâce à quelques caractères à la signification spéciale, une chaîne de caractère servira à décrire tout un ensemble de chaînes de caractères

Pourquoi, comment ? 13

- L'intérêt des expressions régulières tient essentiellement dans deux faits
  1. Elles sont concises
  2. Elles peuvent être transformée facilement en code exécutable
- La traduction d'une expression régulière donne conceptuellement le même genre de code que l'écriture à la main
  - ⇝ La traduction passe par la notion d'automate (cf. chapitre "Langages et Automates")

Standardisation 14

- Les expressions régulières sont plus ou moins standardisées...
- ... Mais souvent plutôt moins que plus !
- Les grands principes restent les mêmes, mais d'un contexte à l'autre de petits détails changent...
- Ce que nous décrirons dans ce cours est valable en python (au moins)
  - Tous les détails sur `http://docs.python.org/lib/re-syntax.html` et `http://www.amk.ca/python/howto/regex/`

Métacaractères 15

- Les caractères spéciaux (ou *metacaractères*) sont

  `. ^ $ * + ? { } [ ] \ | ( )`
- Tous les autres caractères se représentent eux-même
  - Ainsi, l'expression régulière `'toto'` représente exactement la chaîne de caractères `'toto'`
- Le métacaractère `.` représente tout caractère (sauf le retour à la ligne)
  - Ainsi, `HE.Arc` pourra représenter `HE-Arc`, mais aussi `HELArc`, `HE !Arc`, `HEfArc`, ... et même `HE.Arc` !

Métacaractères (suite) 16

- `^ $` début de ligne, fin de ligne
- `[...]` ensemble de caractères. `[ABC]` désigne `A` ou `B` ou `C`, `[A-Z]` n'importe quelle majuscule, `[A-Z0-9]` ...
- `[^...]` tout *sauf* l'ensemble de caractères. `[^A-Z]` désigne n'importe quoi sauf une majuscule.
- `r1|r2` désigne toute expression désignée par `r1` ou par `r2`. Par exemple, bleu|blanc désigne les chaînes `bleu` et `blanc`.
- `(?:...)` a le rôle des parenthèses dans une expression arithmétique. `t(?:oa|e)st` désigne `toast` et `test`.

Classes de caractères prédéfinies 17

- \b désigne le début ou la fin d'un mot. `\bbon` désignera le `bon` de `bonjour` mais pas de `jambon`
- \d équivalent à `[0-9]`
- \D équivalent à `[^0-9]`
- \s désigne un espace blanc (`[\t\n\r\f\v]`)
- \S tout mais pas \s
- \w [a-zA-Z0-9_]
- \W ...

Répétitions 18

- r* 0,1 ou plusieurs fois `r`. Exemple : `ab*` désigne `a`, `ab`, `abb`, ...
- r? 0 ou 1 fois `r`
- r+ 1 ou plusieurs fois `r`
- r{m} *m* fois `r`
- r{m,n} de *m* à *n* fois `r`

La gourmandise est-elle un vilain défaut ? 19

- Par défaut, une expression régulière correspond à la plus longue chaîne possible (comportement "gourmand" ou "glouton", angl. "greedy")

```
>>> re.compile(r'<.*>').findall('<b>gras</b>')
['<b>gras</b>']
```

- Une solution possible : l'exclusion

```
>>> re.compile(r'<[^>]*>').findall('<b>gras</b>')
['<b>', '</b>']
```

- Autre solution : les qualificateurs *non-gourmands* (non-standard !)

```
>>> re.compile(r'<.*?>').findall('<b>gras</b>')
['<b>', '</b>']
```

- Marche avec `*?`, `+?` et `??`

Échappements 20

- On aimerait reconnaître la chaîne `(|)`... comment faire ?
- Les métacaractères peuvent
  - soit être échappés avec `\`
  - soit être inclus dans une classe de caractères `[]`
- Donc par exemple `\([|]{2}\)` désigne `(||)`

L'enfer des échappements 21

- Supposons que l'on veut écrire une expression régulière qui corresponde à des expressions comme `\\labinfo\dfs`
- On peut essayer `"\\.+\.+"`
- Mais :
  - Il faut doubler les backslash dans les chaînes de caractères : `"\\\\.+\\.+"` nous donnera bien la chaîne ci-dessus
  - La chaîne ci-dessus vue comme expression régulière contient encore des échappements ! Il faut donc encore doubler : `"\\\\\\\\.+\\\\.+"`
- Le premier problème peut être résolu avec les *raw strings* en python : `r"\\\\.+\\.+"`

Exemples 22

- Ligne ne contenant que des caractères alphanumériques

  `^\w*$`
- Nombres entiers

  `[-+]?\d+`
- Commentaires (suivant un #)

  `#.*$`
- Chaînes de caractères

  `"[^"]*"`, ou
  `".*?"`
  (mais un simple `".*"` ne marche généralement pas ! !)

Applications 23

- Outils en ligne de commande (grep, find, . . .) et langages de scripts (sed, awk, perl, . . .)

```
local OSS="$(modprobe -l | grep "snd.*oss"
| sed -e "s:\/.*\/::" -e "s:\..*::")"
```

- Éditeurs (emacs, vim, SciTe, . . .)
  - Chercher/remplacer
  - Coloration syntaxique
- Traitements de texte (Openoffice, Word – implémentation partielle)
- Conception de compilateurs (Lex, . . .)
- Bibliothèques dans divers langages de programmation (Java, C#, Python, . . .)
  - Vérification des entrées de l'utilisateur, . . .

Décrire les lexèmes 24

- Avec un générateur, on peut se contenter de fournir une liste de lexèmes avec chacun l'expression régulière correspondante. . .
- . . . et laisser le générateur nous faire un code qui sépare et classifie les lexèmes
- Dans les cas compliqué, on recours parfois aux *descriptions régulières*

Descriptions régulières 25

Description régulière

- Ensemble d'expressions régulières nommées
- On peut réutiliser une expression définie précédemment
- Par contre, une définition récursive est interdite !

- Par substitutions successives, on peut donc se ramener à une expression régulière.

Exemple 26

- "Un identificateur est une suite de lettres, de chiffres et de soulignements qui commence par une lettre ; deux soulignements consécutifs sont interdits, ainsi qu'un soulignement final"
- Description régulière (exemple !) :

```
lettre → [a-zA-Z]
chiffre → [0-9]
souligne → _
lettre_ou_chiffre → lettre | chiffre
fin_soulignee → souligne lettre_ou_chiffre+
identificateur → lettre lettre_ou_chiffre*
fin_soulignee*
```

- Expression régulière équivalente :

```
[a-zA-Z][a-zA-Z0-9]*(_[a-zA-Z0-9]+)*
```


Une question de priorité 27

- L'analyseur lexical doit déterminer quelle suite de caractères correspond à quelle expression régulière
- Que faire si plusieurs solutions sont possibles ?
  - On peut par exemple considérer l'ordre dans lequel les descriptions de lexèmes ont été données.
  - Parfois, la longueur de l'expression régulière et/ou du lexème peut aussi entrer en jeu
- Attention ! Les différents générateurs d'analyseur lexicaux peuvent implémenter des stratégies différentes à ce niveau-là... en cas de doute, lire la doc !

Identification des lexèmes 29

- Dans son acception la plus “propre”, le rôle de l’analyseur lexical est de fournir une suite de lexèmes
- Cependant, dans un certains nombre de cas, il est nécessaire de faire déjà un petit peu de sémantique
- Exemple : identificateur influançant sur la suite de l’analyse

  `Typedef int T;`
  `(T *) var;` ⇝ correct !
  Mais
  `int T;`
  `(T *) var;` ⇝ incorrect !
- Dans certains cas, des traitements sont effectués à ce stade pour augmenter l’efficacité
  - Exemple : la chaîne de caractères “127” peut déjà être convertie en l’entier 127. . .

Table des symboles 30

- Rassemble toutes les informations nécessaires sur les identificateurs
- Les informations récoltées dépendent du compilateur
- Conceptuellement, correspond à un tableau indexé par des chaînes de caractères
  - Dans les langages n’implémentant pas ce concept, il faut se débrouiller. . .

Autres traitements intermédiaires 31

- Inclusion de fichiers
- Compilation conditionnelle
- Généricité
- . . .