Algorithmes, Programmation, IA

Cours 6

Jean-Jacques Lévy

jean-jacques.levy@inria.fr

http://jeanjacqueslevy.net/algo-prog-ia-25

Plan

- fonctions sur les chaînes de caractères
- analyse lexicale
- analyse syntaxique
- évaluation d’expressions arithmétiques

dès maintenant: télécharger Python 3 en `http://www.python.org`

Quelques rappels

- le cours utilise le langage Python et l'environnement Visual Studio Code. (`vscode`)
- et pour la partie IA, la bibliothèque Pytorch

Analyse lexicale

- isoler les mots importants (*lexèmes*) dans une chaîne de caractères (ou fichier de texte)
- suppressioin des espaces, tabulations, retours ligne

```
txt = '(5 + 2 * 3) * (10 * 10 + 9 * 9)'
print (txt.split())
```

```
['(5', '+', '2', '*', '3)', '*', '(10', '*', '10', '+', '9', '*', '9)']
```

- insuffisant car pas de distinction entre *lexèmes* non séparés par des espaces
- automates finis pour les distinguer

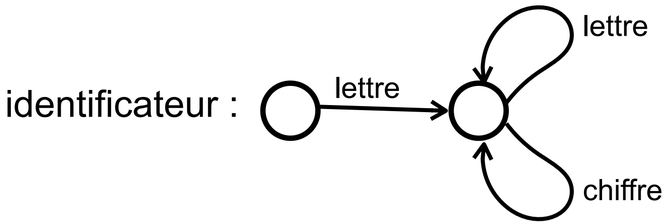

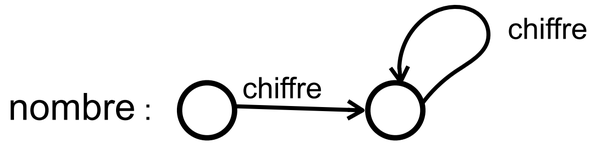

opérateur : { '+', '*', '-', '/' }

parenthèse : { '(', ')' }

Analyse lexicale

- isoler les mots importants (*lexèmes*) dans une chaîne de caractères (ou fichier de texte)

- suppressioin des espaces, tabulations, retours ligne

```
txt = '(5 + 2 * 3) * (10 * 10 + 9 * 9)'
```

```
['(', '5', '+', '2', '*', '3', ')', '*', '(', '10', '*', '10', '+', '9', '*', '9', ')']
```

- description aussi possible avec expressions régulières

$$
\begin{aligned}
lettre &= a|b|\ldots z|A|B|\ldots Z|\_ \\
chiffre &= 0|1|2|3|4|5|6|7|8|9 \\
identificateur &= lettre(lettre|chiffre)^* \\
nombre &= chiffre^+
\end{aligned}
$$

Analyse lexicale

- isoler les mots importants (*lexèmes*) dans une chaîne de caractères (ou fichier de texte)

- suppressioin des espaces, tabulations, retours ligne

```
lettre = {chr(i) for i in range(ord('a'), ord('z') + 1)}
chiffre = {chr(i) for i in range(ord('0'), ord('9') + 1)}
op = {'+', '*', '-', '/'}
par = {'(', ')'}
blancs = {' ', '\t', '\n'}
```

```
class Stream :
    def __init__ (self, txt) :
        self.contents = txt + ' end '
        self.index = 0
    def progress (self) :
        self.index += 1
    def current (self) :
        return self.contents[self.index]
```

marqueur de fin

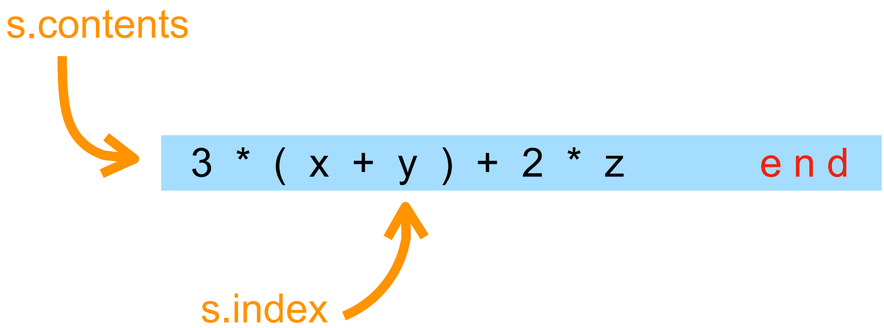


```
def skip_whites (s) :
    while s.current() in blancs :
        s.progress()
```

Analyse lexicale

- isoler les mots importants (*lexèmes*) dans une chaîne de caractères (ou fichier de texte)

- suppressioin des espaces, tabulations, retours ligne

```
def next_lexem (s) :
    skip_whites (s)
    c = s.current()
    if c in lettre:
        return get_ident(s)
    elif c in chiffre:
        return get_number(s)
    elif c in op :
        s.progress()
        return ('OP', c)
    elif c == '(' :
        s.progress()
        return ('PAR0', None)
    elif c == ')' :
        s.progress()
        return ('PAR1', None)
    else: raise Exception ("Caractère illégal")
```

```
def get_ident(s):
    r = ''
    while s.current() in union(lettre, chiffre) :
        r = r + s.current()
        s.progress()
    return ('ID', r)
```

```
def get_number(s):
    r = 0
    while s.current() in chiffre:
        r = r * 10 + ord(s.current()) - ord('0')
        s.progress()
    return ('INT', r)
```

Analyse lexicale

- isoler les mots importants (*lexèmes*) dans une chaîne de caractères (ou fichier de texte)
- suppressioin des espaces, tabulations, retours ligne

```
txt = '3 * (x + y) + 2 * z'
s = Stream (txt)
print ("texte = '%s' " %txt)
for i in range (12) :
    print (next_lexem(s))
```

```
texte = '3 * (x + y) + 2 * z'
('INT', 3)
('OP', '*')
('PAR0', None)
('ID', 'x')
('OP', '+')
('ID', 'y')
('PAR1', None)
('OP', '+')
('INT', 2)
('OP', '*')
('ID', 'z')
('ID', 'end')
```

Arbres de syntaxe abstraite (ASA)

- arbre de syntaxe abstraite représente la structure d'une expression arithmétique
- opérateurs binaires et éléments terminaux (variables, entiers)

```
class BIN_OP:
    def __init__ (self, x, g, d) :
        self.val = x
        self.gauche = g
        self.droit = d

    def __str__ (self) :
        return "BIN_OP ({}, {}, {})".format (self.val, self.gauche, self.droit)

class ELT:
    def __init__ (self, x) :
        self.val = x

    def __str__ (self) :
        return "ELT ({})".format (self.val)
```

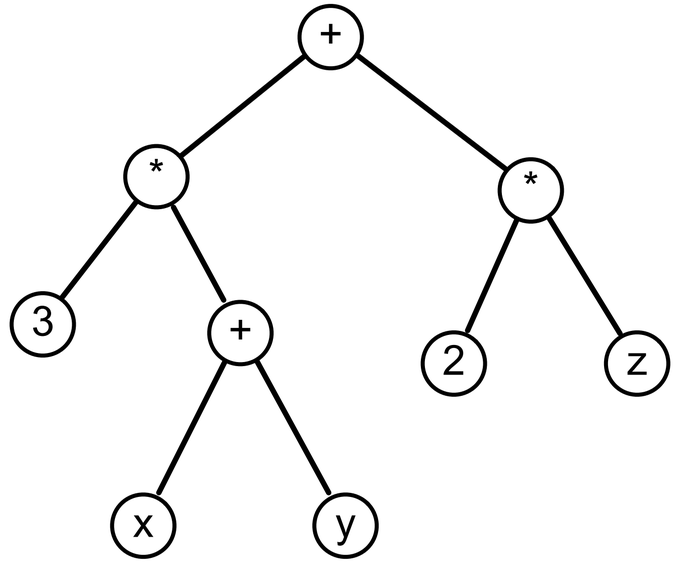

Analyse syntaxique

- compiler le texte pour construire l'ASA correspondant
- analyse lexicale, puis analyse syntaxique (récursive descendante)

```
def compile (txt) :
    global s, lc
    s = Stream (txt)
    lc = next_lexem (s)
    return (expression())
```

`s, lc` stream et lexème courants
(variables globales pour simplifier la programmation)

```
txt = '3 * (x + y) + 2 * z'
t = compile (txt)
print (txt, '-->', t)
```

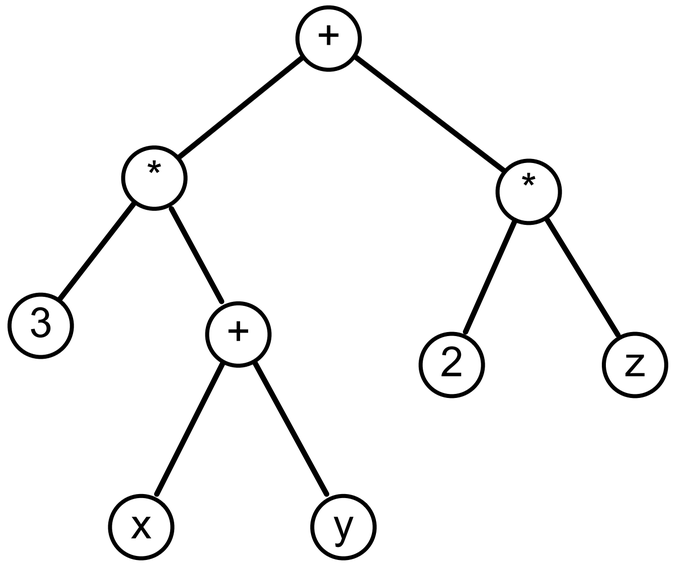

Analyse syntaxique

- compiler le texte pour construire l'ASA correspondant
- analyse lexicale, puis analyse syntaxique (récursive descendante)

```
def avancer () :
    global s, lc
    lc = next_lexem(s)
```

```
def expression () :
    t = produit()
    (kind, val) = lc
    if kind == 'OP' and val in {'+', '-'}:
        avancer()
        return BIN_OP (val, t, expression())
    else :
        return t
```

```
def produit():
    t = facteur()
    (kind, val) = lc
    if kind == 'OP' and val in {'*', '/'} :
        avancer()
        return BIN_OP (val, t, produit())
    else :
        return t
```

```
def facteur() :
    (kind, val) = lc
    if kind == 'PAR0' :
        avancer()
        t = expression()
        (kind, val) = lc
        if kind != 'PAR1' :
            raise Exception ("Il manque ')'")
    elif kind in {'INT', 'ID'} :
        t = ELT (val)
    else :
        raise Exception ("Erreur de syntaxe")
    avancer()
    return t
```

Analyse syntaxique

- compiler le texte pour construire l'ASA correspondant
- analyse lexicale, puis analyse syntaxique (récursive descendante)

```
def compile (txt) :
    global s, lc
    s = Stream (txt)
    lc = next_lexem (s)
    return (expression())
```

`s, lc` stream et lexème courants
(variables globales pour simplifier la programmation)

```
txt = '3 * (x + y) + 2 * z'
t = compile (txt)
print (txt, '-->', t)
```

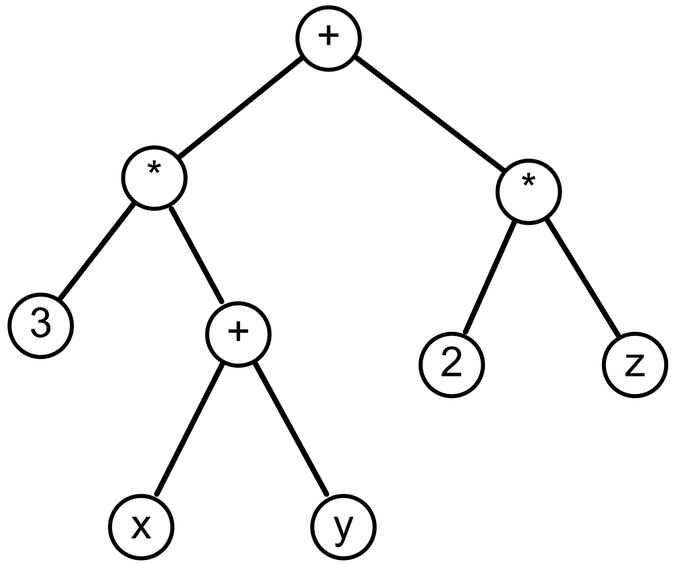

Evaluation

- on calcule l'expression arithmétique dans un environnement où on donne une valeur aux variables

```
def eval (t, e) :
    if isinstance (t, BIN_OP) :
        if t.val == '+' :
            return eval(t.gauche, e) + eval(t.droit, e)
        elif t.val == '-' :
            return eval(t.gauche, e) - eval(t.droit, e)
        elif t.val == '*' :
            return eval(t.gauche, e) * eval(t.droit, e)
        elif t.val == '/' :
            return eval(t.gauche, e) / eval(t.droit, e)
        else:
            raise Exception ('BIN_OP impossible')
    elif isinstance (t.val, int) :
        return t.val
    else:
        return e[t.val]
```

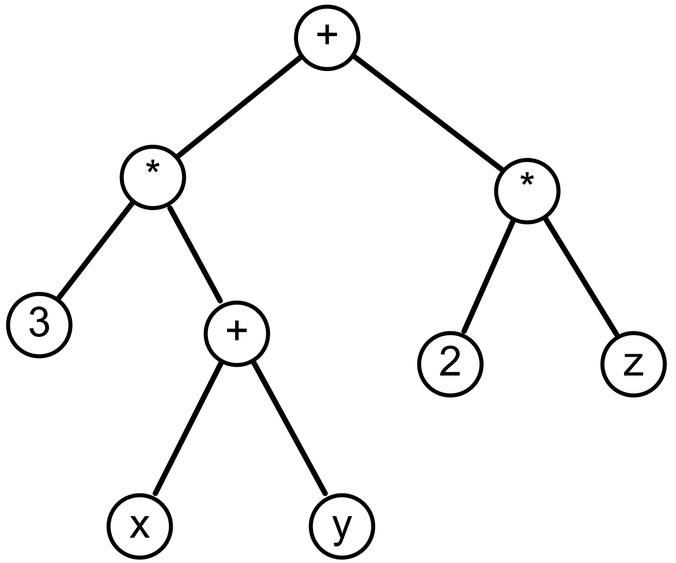


```
env = {'x': 10, 'y':28, 'z':36}
print (env, '-->', eval (t, env))
```

```
{'x': 10, 'y': 28, 'z': 36} --> 186
```

Théorie

- expressions régulières et automates finis

$$
\begin{aligned}
lettre &= a|b|\ldots z|A|B|\ldots Z|\_ \\
chiffre &= 0|1|2|3|4|5|6|7|8|9 \\
identificateur &= lettre(lettre|chiffre)^* \\
nombre &= chiffre^+
\end{aligned}
$$

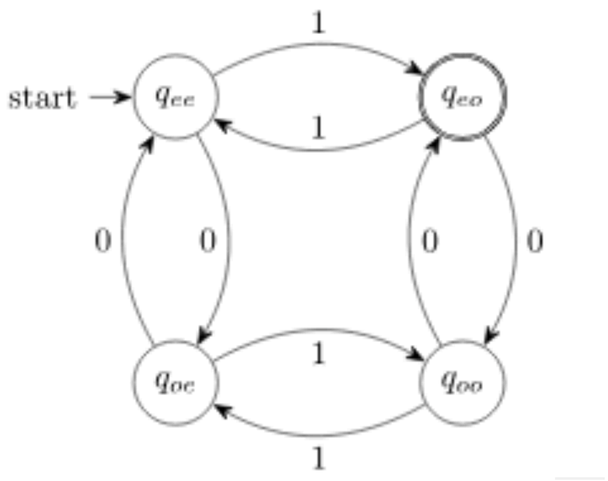

- des milliers de livres `Automata and Computability [D.C. Kozen]`

Théorie

- langages formels (algébriques, rationnels, context-free) [Chomsky - 1956]

$$E \to P \mid P + E \qquad P \to F \mid F \times P$$
$$F \to id \mid nombre \mid (E)$$

- arbre syntaxique d'une expression arithmétique

- des milliers d'articles et livres

- école française [Schutzenberger - 1960]

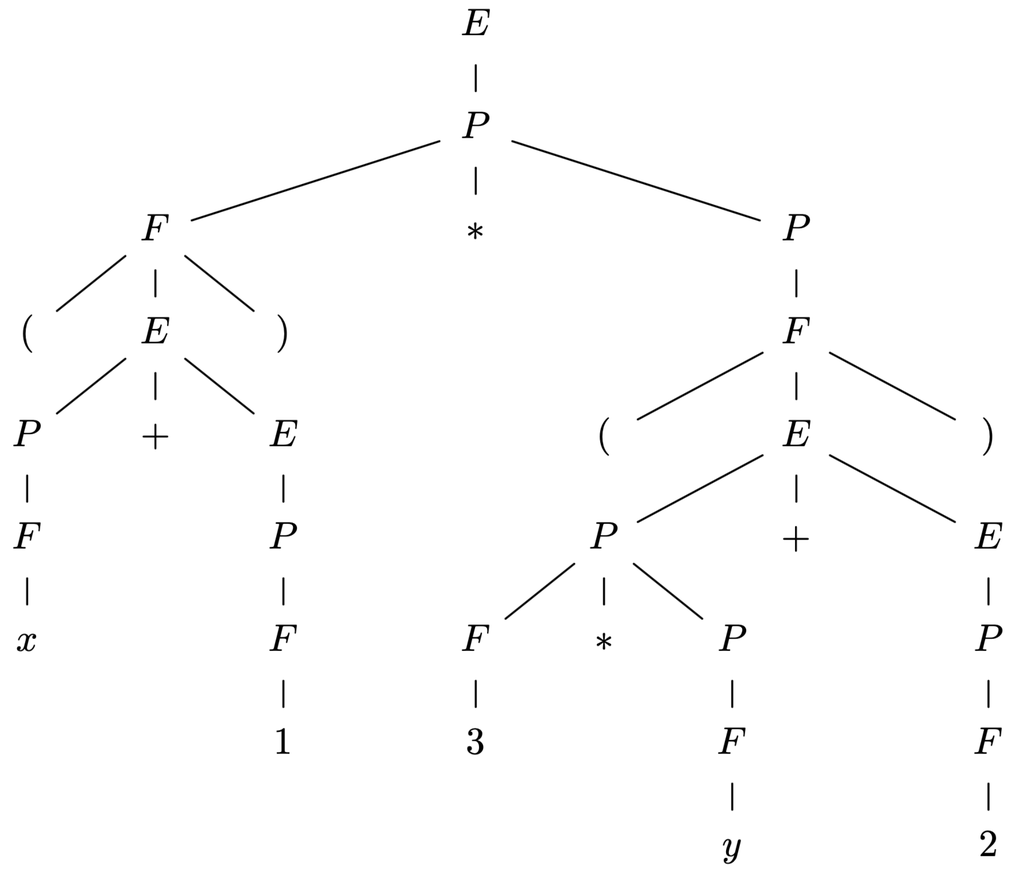

Outils

- le module Python **RegEx** permet de manipuler des expressions régulières
- les modules **PLY** (Python Lex-Yacc)
- **Lex** permet de générer un analyseur lexical à partir d'expressions régulières `[M. Lesk - Unix 1975]`
- **Yacc** génère un analyseur syntaxique à partir d'une description de grammaire LR(k) `[S.C. Johnson - Unix 1975]`
  - la méthode récursive descendante a des limitations (pas de récursivité gauche)
  - les méthodes ascendantes LR(k) sont plus générales
- **BNF** (Backus Naur Form) est une forme pour écrire la grammaire formelle des langages de programmation
- la grammaire pour le langage Python se trouve en `https://docs.python.org/3/reference/grammar.html`

Prochain cours

- calcul numérique
- nombres flottants IEEE
- méthode de Newton
- régression linéaire