

Reconnaissance de motifs

UMLV ©

Problème

localiser les segments d'un texte décrits
par une expression rationnelle (régulière) r

texte t

segment x
décrit par r

Applications

édition : vi, emacs , sed, ed, ...
recherche : grep, egrep , ...
traduction : lex, sed , ...
langages : awk, perl, ...
compression : compress, gzip, ...

701

GREP

UMLV ©

```
unix > grep toto t.txt
```

produit les lignes de **t.txt**
qui contiennent le mot **toto**

Applications

recherche de fichiers par le contenu
contrôle du contenu d 'un fichier

Versions

egrep, fgrep, ...

702


Algorithme de base

UMLV ©

Deux phases

- 1 génération d'un automate $A(r)$
- 2 analyse du texte avec $A(r)$

les phases peuvent être intégrées



703

Expression / langage

UMLV ©

Expression rationnelle r

$a, b, \dots$

$\emptyset, \epsilon$

$[u, v]$

(u)

$u + v$

uv

u^*

Langage représenté $L(r)$

$\{a\}, \{b\}, \dots \quad a, b \in A$

$\emptyset, \{\text{mot vide}\}$

$L(u), L(v)$

$L(u)$

$L(u) \cup L(v)$

$\{xy \mid x \in L(u), y \in L(v)\}$

$\{x_1 x_2 \dots x_k \mid k \geq 0, x_i \in L(u)\}$

$1(0+1)^*0$

$(a^*b)^*a^*$

$(c^*1)^*c^*f$

{écritures binaires des entiers pairs}

{suites finies de a et b }

{fichiers textes}

704

Analyse des expressions

UMLV ©

Une grammaire des expressions rationnelles

$$\begin{aligned} E &\mathbb{R} T \mid T '+' E \\ T &\mathbb{R} F \mid FT \\ F &\mathbb{R} SG \\ G &\mathbb{R} e \mid '*' G \\ S &\mathbb{R} 'a' \mid 'b' \mid '\epsilon' \mid 'e' \mid '(' E ')' \end{aligned}$$

E expression, T terme
 F facteur, S facteur simple

$(a+b)*c$ {suites finies de a et b terminées par c }


705

Analyse de $(a+b)*c$

UMLV ©

Arbre de l'analyse


Grammaire

$$\begin{aligned} E &\mathbb{R} T \mid T '+' E \\ T &\mathbb{R} F \mid FT \\ F &\mathbb{R} SG \\ G &\mathbb{R} e \mid '*' G \\ S &\mathbb{R} 'a' \mid 'b' \mid '\epsilon' \mid 'e' \mid '(' E ')' \end{aligned}$$


706

Diagrammes syntaxiques

UMLV ©



707

Algorithme d'analyse

UMLV ©

```

caractère car; /* caractère suivant, global */

Analyse(expression rationnelle r){
    car ← premier caractère de r ;
    Expression();
    si(car ≠ fin d'expression)
        erreur();
}

Expression(){
    Terme();
    si(car = '+'){
        car ← caractère suivant;
        Expression();
    }
}

Terme(){
    Facteur();
    si(car ∈ {'a', 'b', 'Æ', 'e', '('})
        Terme();
}
    
```

708

Algorithme d'analyse (suite)

UMLV ©

```


Facteur(){
  si(car ∈ {'a','b','Æ','e'}){
    car ← caractère suivant;
  }sinon si(car = '('){
    car ← caractère suivant;
    Expression();
    si(car = ')')
      car ← caractère suivant;
    sinon
      erreur();
  }sinon
    erreur();
  tant que(car = '*')
    car ← caractère suivant;
}

```

709

Diagrammes syntaxiques (autre)

UMLV ©



710

Algorithme d'analyse (autre)

UMLV ©

```
caractère car; /* caractère suivant, global */

Analyse(expression rationnelle r){
    car  $\leftarrow$  premier caractère de r ;
    Expression();
    si(car  $\neq$  fin d'expression)
        erreur();
}
Expression(){
    Terme();
    tant que(car = '+'){
        car  $\leftarrow$  caractère suivant;
        Terme();
    }
}
Terme(){
    répéter
        Facteur();
    tant que(car  $\in$  {'a', 'b', 'Æ', 'e', '('})
}
```

711

Expression / automate

UMLV ©

$A(r)$ automate associé à l'expression rationnelle r
sur l'alphabet A

Invariants de la construction


- $A(r)$ possède un seul état initial i
- un seul terminal t
- aucune flèche n'entre dans i
- aucune flèche ne sort de t

Graphique

$A(r)$:



712



713

UMLV ©

Automate obtenu

Proposition
 $A(r)$ reconnaît le langage $L(r)$


Propriétés supplémentaires
 $A(r)$ possède $2 \cdot |r|$ états, sans compter '(' ni ')'
 de chaque état sortent au plus 2 flèches
 si exactement 2, elles sont sans étiquette
 sur chaque état arrivent au plus 2 flèches

714

Exemple

UMLV ©

Expression : $(b^* + aa + ab)^*b$



bab reconnu ?

non, mais infinité de chemins d'origine 17 et d'étiquette **bab**

715

Implantation adaptée

UMLV ©

état = indice
table des flèches

```
struct{
    caractère lettre;
    état suiv1, suiv2;
} Trans[MAX];
automate (identifié à 2 états)
struct{
    état initial;
    état terminal;
} automate;
```

Trans

p	'a'	p1	
q		q1	q2

initial = 17
terminal = 20

1	'b'	2	
2		1	4
3		1	4
4		10	
5	'a'	6	
6		7	
7	'a'	8	
8		10	
9		3	5
10		16	
11	'a'	12	
12		13	
13	'b'	14	
14		16	
15		0	11
16		15	18
17		15	18
18		10	
19	'b'	20	
20			

716

Algorithme de traduction

UMLV ©

Production de l'automate $A(r)$
associé à l'expression rationnelle r

```
Analyse(expression rationnelle r){  
    car  $\leftarrow$  premier caractère de  $r$  ;  
    A  $\leftarrow$  Expression();  
    si(car  $\neq$  fin d'expression)  
        erreur();  
    sinon  
        retour A;  
}
```

717

Algorithme de traduction (suite)

UMLV ©

```
Expression(){  
    A  $\leftarrow$  Terme();  
    tant que(car = '+'){  
        car  $\leftarrow$  caractère suivant;  
        B  $\leftarrow$  Terme();  
        A  $\leftarrow$  Union(A,B);  
    }  
    retour A;  
}  
Terme(){  
    A  $\leftarrow$  Facteur();  
    tant que(car  $\in$  {'a','b','Æ','e','('}){  
        B  $\leftarrow$  Facteur();  
        A  $\leftarrow$  Produit(A,B);  
    }  
    retour A;  
}
```

718

Algorithme de traduction (suite)

UMLV ©

```
Facteur(){
  si(car ∈ {'a', 'b', 'Æ', 'e'}){
    A ← Automate-élémentaire(car);
    car ← caractère suivant;
  }sinon si(car = '('){
    car ← caractère suivant;
    A ← Expression();
    si(car = ')')
      car ← caractère suivant;
    sinon
      erreur();
  }sinon
    erreur();
  tant que(car = '*'){
    A ← Etoile(A);
    car ← caractère suivant;
  }
  retour A ;
}
```

719

Reconnaissance (avec automate non-déterministe)

UMLV ©

Écrire une fonction

booléen reconnaît(automate A , mot x)
qui prend la valeur vraie ssi
il existe un chemin d'étiquette x depuis $A.initial$ jusqu'à $A.terminal$


Programmation par

essais et erreurs (attention aux cycles)
programmation dynamique (mémorisation des états possibles)


Clôture

$cl\acute{o}ture(p) = \{ \text{états accessibles à partir } p \\ \text{par chemins sans étiquette} \}$

720



721




722

Reconnaissance (suite)

UMLV ©

Expression : $(b^* + aa + ab)^*b$ Reconnaissance de **bab**




Transition par **b** {1, 3, 4, 5, 9, 10, 11, 15, 16, 17, 18, 19}
 Clôture {2, 20}

723

Reconnaissance (suite)

UMLV ©

Expression : $(b^* + aa + ab)^*b$ Reconnaissance de **bab**




Transition par **a** {6, 12}
 Clôture {6, 7, 12, 13}

724

Reconnaissance (suite)

UMLV ©

Expression : $(b^* + aa + ab)^*b$ Reconnaissance de **bab**



Transition par **b** {6, 7, 12, 13}
 {14}
 Clôture {1, 3, 4, 5, 9, 10, 11, 14, 15, 16, 18, 19}
bab non reconnu car 20 non atteint

725

Algorithme de reconnaissance

UMLV ©

```

booléen reconnaît(automate A, mot x){
    ensemble E;
    E ← clôture(A.initial);
    tant que(non fin de x){
        car ← lettre suivante de x;
        E ← clôture(transition(E,car));
    }
    si(A.terminal ∩ E) retour(vrai);
    sinon retour(faux);
}
    
```

Lecture séquentielle du mot.
 Mémorisation (tampon) d'une seule lettre de x.
 Temps : $O(\text{nb états de } A \cdot |x|)$
 (si bonne gestion de l'ensemble E)

726

Recherche de motif

UMLV ©

Motif défini par l'expression rationnelle r
 $A(r)$ automate associé à r

Motif dans le texte

texte t

segment x
reconnu par $A(r)$, $x \in L(r)$

Principe de la recherche

comme reconnaissance avec :
ajout l'état initial à chaque position
arrêt de la recherche dès que l'état terminal est atteint

727

Algorithme de recherche

UMLV ©

```
booléen recherche(automate A, mot t){  
    ensemble E;  
    E ← clôture(A.initial);  
    tant que(non fin de t){  
        car ← lettre suivante de t;  
        E ← clôture({A.initial} ∪ transition(E, car));  
        si(A.terminal ∩ E) retour(vrai);  
    }  
    retour(faux);  
}
```


Lecture séquentielle du texte.

Mémorisation (tampon) d'une seule lettre de t .

Temps : $O(\text{nb états de } A \cdot |t|)$

(si bonne gestion de l'ensemble E)

728




729

UMLV ©

	<i>déterminisation</i>	<i>simulation</i>
temps de la recherche	$O(t)$	$O(r \cdot t)$
espace	$O(2^{ r })$	$O(r)$

730



731

UMLV ©

```

% { /* définitions des constantes littérales */
    PPQ, PPE, EGA, DIF, PGQ, PGE,
    SI, ALORS, SINON, ID, NB, OPREL
% }
/* définitions régulières */
délim      [ \t\n ]
bl         {delim}+
lettre     [A-Za-z]
chiffre    [0-9]
id         {lettre}+({lettre}|{chiffre})*
nombre     {chiffre}+(\.{chiffre}+)?(E[+\-]?{chiffre}+)?
%%
{bl}       { /* pas d'action et pas de retour */ }
si         {return (SI) ; }
alors      {return (ALORS) ; }
sinon      {return (SINON) ; }
{id}       {yyval = RangerId ( ) ; return (ID) ; }
{nombre}   {yyval = RangerNb ( ) ; return (NB) ; }
"<"       {yyval = PPQ ; return (OPREL) ; }
"<="      {yyval = PPE ; return (OPREL) ; }
"="        {yyval = EGA ; return (OPREL) ; }
"<>"      {yyval = DIF ; return (OPREL) ; }
">"       {yyval = PGQ ; return (OPREL) ; }
">="      {yyval = PGE ; return (OPREL) ; }
  
```

732

```


%%
RangerId(){
    /* procédure qui range dans la table des symboles
       le lexème dont le premier caractère est pointé
       par yytext et dont la longueur est yyleng,
       et retourne un pointeur sur son entrée */
    ...
}

RangerNb(){
    /* procédure similaire pour ranger un lexème
       qui est un nombre */
    ...
}


```

Recherche d'un mot

Recherche des positions du mot x dans le texte t
 Par balayages (gauche-droite) et décalages



Variables de travail



Algorithme naïf

UMLV ©

```
Naif(mot x, longueur m, mot t, longueur n){
    j ← 0; i ← 0;
    tant que (i < m) et (j < n){
        si (x[i] = t[j]){
            j ← j+1; i ← i+1;
        } sinon {
            j ← j-i+1; i ← 0;
        }
    }
    fin ;
    si (i > m) écrire(mot trouvé à la position j-i);
    sinon écrire(pas d'occurrence de x dans t);
}
```

Temps maximal $O(m.n)$

» $m.n$ comparaisons au pire

Temps moyen $O(n)$


» $2.n$ comparaisons moyennes sur alphabet binaire
(équiprobabilité et indépendance)

735

Méthode de Knuth, Morris & Pratt

UMLV ©

KMP : balayages gauche-droite et décalages **compatibles**



Bords : Bord(abacaba) = aba


Longueur des bords des préfixes : $bord[i] = |\text{Bord}(x[0..i-1])|$

i	0	1	2	3	4	5	6	7	8
$x[i]$	a	b	a	c	a	b	a	d	
$bord[i]$	-1	0	0	1	0	1	2	3	0

736

Recherche KMP

UMLV ©



737

Algorithme

UMLV ©

```
KMP(mot x, longueur m, mot t, longueur n){
    j ← 0 ; i ← 0 ;
    tant que (i < m) et (j < n){
        tant que (i > 0) et (x[i] ≠ t[j])
            i ← bord[i] ;
        j ← j+1 ; i ← i+1 ;
    }
    si (i = m) écrire(mot trouvé à la position j-m);
    sinon écrire(pas d'occurrence de x dans t);
}
```

Temps $O(n)$

moins de $2.n$ comparaisons

recherche séquentielle (j ne décroît jamais)

recherche linéaire mais pas en temps réel

738

Calcul des bords

UMLV ©


Bords : $\text{Bord}(u)$ = plus long préfixe et suffixe propre de u

Note : le bord d'un bord est un bord

$\text{Bord}(\text{a b a c a b a c}) = \text{a b a c}$

$\text{Bord}(\text{a b a c a b a b}) = \text{a b}$

$\text{Bord}(\text{a b a c a b a d}) = \epsilon$



si $a = a'$ $\text{bord}[i+1] = \text{bord}[i] + 1 = j + 1$
 sinon faire le calcul avec a sur $\text{Bord}(x[0 .. j-1])$

739

Algorithme


UMLV ©

```

BORDS(mot x, longueur m){
    bord[0] ← -1 ;
    pour i ← 0 à m-1 faire {
        j ← bord[i] ;
        tant que (j ≥ 0) et (x[i-1] ≠ x[j])
            j ← bord[j] ;
        bord[i+1] ← j+1 ;
    }
    retour bord ;
}
    
```

Temps $O(m)$, moins de $2.m$ comparaisons}

Comme la recherche !




740

Méthode de Boyer-Moore (simplifiée)


UMLV ©

BM : balayages **droite-gauche** et décalages compatibles avec la lettre différente du texte



Positions


a	a	b	c	d	e	...
$Pos_x[a]$	1	6	2	8	8	...



741

Recherche BM

UMLV ©



Valeurs de i et j après décalage

$i' = m$

$j' = j + Pos_x[t[j]]$ si $Pos_x[t[j]] > m - i + 1$

$m - i + 1$ sinon

742

Algorithme BM

UMLV ©

```

BM(mot x, longueur m, mot t, longueur n){
  j ← m-1 ; j ← m-1 ;
  tant que (i ≥ 0) et (j < n)
    si(x[i] = t[j]){
      j ← j-1 ; i ← i-1 ;
    } sinon {
      j ← j + max{Pos[j], m-i+1} ; i ← m-1 ;
    }
  si (i = -1) écrire(mot trouvé à la position j+1);
  sinon écrire(pas d'occurrence de x dans t);
}

```

Temps maximal $O(m.n)$

Temps, sur des textes en langue naturelle, proche du minimal : $\Theta(n/m)$

743


Calcul de Pos

UMLV ©

```

Positions(mot x, longueur m){
  pour chaque lettre a faire
    Pos[a] ← m ;
  pour i ← 0 à m-2 faire
    Pos[x[i]] ← m-i-1 ;
  retour Pos ;
}

```



Temps $O(m + \text{card } A)$

744