

Logică și structuri discrete

Gramatici

Cassandra Holotescu
cassandra@cs.upt.ro

<https://tinyurl.com/lecturesLSD>

Recapitulare: Automate

Automatele pot descrie comportamentul unui sistem simplu.
din fiecare stare s , intrarea σ determină starea următoare s'

Un automat *recunoaște* un limbaj (face parte sirul din limbaj?)
ex. program cu comentarii încheiate corect

Traductoare: automate care produc ieșiri (în funcție de intrare)
putem *prelucra* limbaje (ex. elimina comentarii)

Automatele se pot reprezenta *eficient*:
tabel de tranziții:

st	a	b	c
0	1	0	0
1	1	2	0
2	1	0	3
3	1	0	0

⇒ putem determina eficient dacă un sir e acceptat
parcurgem sirul, la fiecare pas tabelul ne dă starea următoare

Recapitulare: Expresii regulate

Expresiile regulate reprezintă concis *limbaje regulate*, ca automatele

Sunt mai ușor de compus (din concatenare, alternativă, repetiție)

Putem să căutăm *tipare* în text, de exemplu identificăm:

șir nevid de cifre: [0-9] +

"images/d61_2016-07-06/logo-57x60.png" sizes="32x32"

sau o dimensiune (de imagine): [0-9] + x [0-9] +

"images/d61_2016-07-06/logo-57x60.png" sizes="32x32"

Pentru căutări, expresiile regulate se traduc în automate
(mai eficient de lucrat)

Limbaje formale, în general

Dorim să:

descriem un limbaj (cât mai simplu/clar/concis)

recunoaștem dacă un sir aparține unui limbaj,

generăm siruri dintr-un limbaj

sau să *transformăm* astfel de siruri

Limbaje care nu sunt regulate

Există limbaje foarte simple care nu sunt regulate:

- | | |
|----------------------------------|-----------------------------------|
| $\{a^n b^n \mid n \geq 0\}$ | paranteze echilibrate, ((())) |
| $\{ww \mid w \in \{a, b\}^*\}$ | cuvânt, apoi repetat |
| $\{ww^R \mid w \in \{a, b\}^*\}$ | cuvânt, apoi inversat (palindrom) |

Automatele finite au *memorie finită*

număr finit de stări \Rightarrow nu pot *număra* mai mult de atât

Pentru primul caz, ar trebui să *numărăm* n de a, cu n nelimitat

În cazul 2 și 3, ar trebui să memorăm cuvinte de lungime arbitrară ca să le comparăm ulterior.

Exemplu: $a^n b^n$ nu e limbaj regulat

$a^n b^n$: numărăm câți a apar, verificăm că sunt la fel de mulți b .

Demonstrăm prin *reducere la absurd*.

Fie un automat determinist cu n stări care acceptă limbajul.

Fie sirul $a^n b^n$ (cu același n) și stările $s_0 \xrightarrow{a} s_1 \xrightarrow{a} \dots \xrightarrow{a} s_n$.

mai departe, din s_n automatul acceptă b^n .

Din $n+1$ stări $s_0 \dots s_n$, doar n pot fi diferite: există $i < j$ cu $s_i = s_j$
 (sirul de stări are un *ciclu* pe parcurs)

Atunci $s_i \xrightarrow{a} \dots \xrightarrow{a} s_j$ e un ciclu ($s_j = s_i$). Îl repetăm încă o dată:
 $j - i$ simboluri a mai adăugăm $j - i$ de a

Continuând apoi din s_j ajungem tot în s_n , dar am consumat a^{n+j-i}
 \Rightarrow automatul acceptă $a^{n+j-i}b^n$ (mai mulți a decât b), *contradictie*.

Lema de pompare pt. limbaje regulate (*pumping lemma*)

Exemplul anterior e un caz particular al unei proprietăți generale

Lema de pompare (informal): În orice limbaj regulat
orice cuvânt suficient de lung conține un subșir ce poate fi repetat

Fie L un *limbaj regulat*. Notăm cu $|w|$ lungimea cuvântului $w \in L$.

Lema de pompare

$\exists p \in \mathbb{N}$ astfel ca orice cuvânt $w \in L$ cu $|w| \geq p$ (destul de lung) are forma $w = xyz$ cu

$|y| \geq 1$ se repetă un subșir nevid

$|xy| \leq p$ subșirul apare înainte de limita p

$\forall k \geq 0 . xy^k z \in L$ y poate fi repetat arbitrar între x și z

Demonstrația lemei de pompare

Fie un limbaj regulat și automatul care-l recunoaște.


Alegem *lungimea de pompare* $p =$ numărul de stări din automat.

Fie sirul $a_1a_2\dots a_m$ cu $m \geq p$, și stările parcuse de automat:

$$q_0 \xrightarrow{a_1} q_1 \xrightarrow{a_2} q_2 \dots \xrightarrow{a_s} q_s \xrightarrow{a_{s+1}} q_{s+1} \dots \xrightarrow{a_t} q_t \dots \xrightarrow{a_m} q_m$$

Avem $m + 1 > p$ stări, deci cel puțin o stare se repetă (ciclul):

$$q_s = q_t \text{ cu } s, t \leq m$$



https://en.wikipedia.org/wiki/Pumping_lemma_for_regular_languages

Parcurgând sirul $y = a_{s+1}\dots a_t$ din q_s ajungem înapoi în $q_t = q_s$ deci putem repeta sirul y , și xy^iz e în limbajul acceptat, q.e.d.

Limbajele de programare trebuie descrise precis

Expresiile regulate nu ajung pentru a descrie limbaje (chiar uzuale).

Din standardul C:

(6.8.4) *selection-statement*:

```
if ( expression ) statement  
if ( expression ) statement else statement  
switch ( expression ) statement
```

(6.8.5) *iteration-statement*:

```
while ( expression ) statement  
do statement while ( expression ) ;  
for ( expressionopt ; expressionopt ; expressionopt ) statement  
for ( declaration expressionopt ; expressionopt ) statement
```

Sintaxa limbajelor de programare e descrisă prin *gramatici*.

Gramatica limbajului natural

Exemplu: propoziții în limba engleză (mult simplificat)

A good student reads books.

$S \rightarrow NP\ VP$

noun phrase + verb phrase

$NP \rightarrow subst$

simplu: doar substantiv

$NP \rightarrow det\ NP$

cu parte determinantă (art/adj)

$VP \rightarrow verb$

predicat simplu: doar verb

$VP \rightarrow verb\ NP$

verb cu complement

Am descris limbajul prin *reguli de producție* (de *rescriere*)

Simbolurile folosite în regulile de producție sunt:

neterminale: simboluri care apar în stânga → (sunt înlocuite)

terminale: simboluri care apar numai în dreapta →

O gramatică descrie un limbaj

Orice limbaj e descris prin *simbolurile* și *sintaxa* sa:
regulile după care simbolurile pot fi combinate corect.

O *gramatică* descrie cum se obțin sirurile unui limbaj
prin *reguli de producție* (*reguli de rescriere*)
pornind de la un *simbol de start*

O *derivare* a unui sir dintr-o gramatică e o secvență de aplicări a
regulilor de producție care transformă simbolul de start în sirul dat.
indicăm la fiecare pas și simbolul transformat

O derivare ne arată că sirul aparține limbajului definit de gramatică.

S → *NP VP* → *NP verb NP* → *NP verb noun*
→ *det NP verb noun* → *det det NP verb noun*
→ *det det noun verb noun* → *a good student reads books*

Derivare. Derivare leftmost/rightmost

Formal, dacă x și y sunt forme propoziționale și $\alpha \rightarrow \beta$ este o regulă de producție, atunci numim *derivare* înlocuirea lui α cu β în $x\alpha y$ și notăm: $x\alpha y \rightarrow x\beta y$

Avem 2 tipuri de derivare:

leftmost: la fiecare pas rescriem neterminálul cel mai din **stânga**


$S \rightarrow NP\ VP \rightarrow det\ NP\ VP \rightarrow det\ det\ NP\ VP$
 $\rightarrow det\ det\ noun\ VP \rightarrow det\ det\ noun\ verb\ NP$
 $\rightarrow det\ det\ noun\ verb\ noun \rightarrow a\ good\ student\ reads\ books$

rightmost: la fiecare pas rescriem neterminálul cel mai din **dreapta**

$S \rightarrow NP\ VP \rightarrow NP\ verb\ NP \rightarrow NP\ verb\ noun$
 $\rightarrow det\ NP\ verb\ noun \rightarrow det\ det\ NP\ verb\ noun$
 $\rightarrow det\ det\ noun\ verb\ noun \rightarrow a\ good\ student\ reads\ books$

Arborele de derivare

Arborele de derivare e o reprezentare *ierarhică* a unei derivări, scriind partea dreaptă a fiecărei reguli sub partea stângă:



Exemple de limbaje definite prin gramatici

Şirurile de paranteze echilibrate:

orice paranteză deschisă $($ are o pereche încisă $)$

o paranteză se închide *după* închiderea celor deschise după ea

(1) $S \rightarrow \epsilon$ (notație pentru sirul vid)

(2) $S \rightarrow (S)S$

Derivare leftmost pt $((())()$): $S \xrightarrow{2} (\underline{S})S \xrightarrow{2} ((\underline{S})S)S \xrightarrow{1} ((S)S)S \xrightarrow{1}$
 $((())S \xrightarrow{2} ((())\underline{S})S \xrightarrow{1} ((())()S \xrightarrow{1} ((())()$

la fiecare pas, am colorat **neterminalul** transformat, am indicat regula folosită $\xrightarrow{1}$ sau $\xrightarrow{2}$ și am subliniat în ce se transformă

$\{ww^R \mid w \in \{a, b\}^*\}$ cuvânt+invers (palindrom, lungime pară)

$S \rightarrow \epsilon$

$S \rightarrow aSa$

$S \rightarrow bSb$

Gramatică formală

O gramatică formală G e formată din:

Σ : o mulțime de simboluri *terminale*

(din care se formează sirurile limbajului)

N : o mulțime de simboluri *neterminale*, $N \cap \Sigma = \emptyset$

(folosite doar în descrierea gramaticii, nu apar în limbaj)

P : o mulțime de *reguli de producție*, de forma

$(\Sigma \cup N)^* N (\Sigma \cup N)^* \rightarrow (\Sigma \cup N)^*$

un neterminal N , eventual într-un context (sir în stânga/dreapta)

e rescris cu un sir de terminale și neterminale

$S \in N$: un *simbol de start*

Limbajul definit de G e format din toate sirurile de *terminale*

care se pot obține din S printr-o derivare (aplicând oricâte reguli)

Gramatici recursive

O regulă de producție este *recursivă* dacă partea ei stângă (neterminalul ce va fi rescris + contextul său) apare și în partea ei dreaptă. Obs: o regulă recursivă se poate refolosi de oricâte ori.

Exemplu:

$$S \rightarrow aSa$$

$$bA \rightarrow bbA$$

O regulă de producție $A \rightarrow \beta$ este *indirect recursivă* dacă A poate fi derivat într-o formă ce îl conține pe A .

Exemplu:

$$S \rightarrow aBa$$

$$B \rightarrow bSb$$

O gramatică este *recursivă* dacă și numai dacă aceasta conține cel puțin o regulă de producție recursivă sau indirect recursivă.

Gramatici recursive și limbaje infinite

O gramatică a unui *limbaj infinit* (șiruri de lungime nelimitată) trebuie să fie *recursivă*.

Altfel, dacă avem n reguli de producție nerecursive

- ⇒ pt. derivarea unui sir putem avea *maxim n* pași de derivare
- ⇒ lungimea sirurilor este *limitată*

Ca să avem $n + 1$ sau mai mulți pași de derivare a unui sir ar trebui să *refolosim* cel puțin o regulă de producție

- ⇒ regula de producție trebuie să fie *recursivă*

Ierarhia Chomsky [după Noam Chomsky]

Notăm: neterminale A, B ; terminale: a, b ; siruri arbitrare: α, β, γ

3) gramatici *regulate*: generează *limbaje regulate*

reguli de forma:

$A \rightarrow a, A \rightarrow \epsilon, A \rightarrow aB$ (regulate la dreapta), SAU

$A \rightarrow a, A \rightarrow \epsilon, A \rightarrow Ba$ (regulate la stânga), NU le combinăm

Conversie în automate: câte o stare pentru fiecare neterminal,

$A \rightarrow aB$ devine $\textcircled{A} \xrightarrow{a} \textcircled{B}$, $A \rightarrow a$ devine $\textcircled{A} \xrightarrow{a} \textcircled{\circ}$ (accept)

2) gramatici *independente de context*

reguli: $A \rightarrow \gamma$ stânga: neterminal; dreapta: sir arbitrar

1) gramatici *dependente de context*

reguli: $\alpha A \beta \rightarrow \alpha \gamma \beta$ A e rescris dacă apare între α și β
 $\gamma \neq \epsilon$ (nevid), sau $S \rightarrow \epsilon$ doar dacă S nu apare în dreapta

0) gramatici nerestricționate (orice reguli de rescriere)

limbaje *recursiv enumerabile* (recunoscute de o mașină Turing)

Forma Backus-Naur (BNF)

dupa John Backus (dezvoltatorul limbajului FORTRAN)
și Peter Naur (ALGOL 60) (fiecare: premiul *Turing*)

Notație frecvent folosită pentru gramatici independente de context

folosește `::=` pentru definiție și `|` pentru alternativă

Neterminal `::= rescriere1 | rescriere2 | ... | rescriereN`

uneori folosite cu extensii:

`[element-optional]`

`simbol*` (steaua Kleene) pentru repetiție

`simbol+` (plus) pentru repetiție cel puțin odată

paranteze pentru gruparea elementelor

Exemple: instrucțiuni în C (simplificat)

Stmt ::= ExpStmt | IfStmt | WhileStmt | Block

ExpStmt ::= expr ;

IfStmt ::= if (expr) Stmt else Stmt | if (expr) Stmt

WhileStmt ::= while (expr) Stmt

Block ::= { Stmt* }

Problema: cu care **if** se potrivește **else** ?

if (x > 0) **if** (y > 0) x = 0; **else** y = 0;


Gramatici ambigue

Înțelesul unui sir dintr-un limbaj e strict legat de *arborele de derivare* al sirului. Acesta ar trebui sa fie *unic*.


O gramatică e *ambiguă* dacă există cel puțin un sir cu mai mulți *arbori de derivare* (arbori sintactici) *diferiți*

– sau, echivalent, dacă există cel puțin un sir cu mai multe derivări leftmost/rightmost *diferite*.

if ($x > 0$) **if** ($y > 0$) $x = 0$; **else** $y = 0$;



interpretarea corectă



interpretare incorectă (trebuie eliminată)

Exemplu de dezambiguare

Pentru a **dezambigua** gramatica, trebuie **rescrisă**: distingem între
un **if echilibrat**, care are **else**
un **if neechilibrat**, fără **else**

Cum **else** e asociat cu cel mai apropiat **if**, ramura **then** e
întotdeauna echilibrată (definim echilibrate restul de instrucțiuni).

Stmt ::= BalancedStmt | UnBalancedIf

BalancedStmt ::= ExpStmt | WhileStmt | Block | BalancedIf

ExpStmt ::= expr ;

WhileStmt ::= **while** (expr) Stmt

Block ::= { Stmt* }

BalancedIf ::= **if** (expr) BalancedStmt **else** Stmt

UnBalancedIf ::= **if** (expr) Stmt

Expresii aritmetice (1)

v1) $E ::= \text{num} \mid E + E \mid E - E \mid E * E \mid E / E \mid (E)$

și aici avem *ambiguitate*:

nu e precizată precedența operatorilor


v2) Rescriem pe 3 nivele de *precedență*:

$E ::= T \mid E + T \mid E - T$

$T ::= F \mid T * F \mid T / F$

$F ::= \text{num} \mid (E)$

Exemplu: $2 * (5 - 3)$



Expresii aritmetice (2)

În această scriere, E apare primul în stânga producțiilor lui E recursivitate *la stânga* \Rightarrow nu putem implementa direct (nu știm când să oprim apelul recursiv)

$E ::= T \mid E + T \mid E - T$

$T ::= F \mid T * F \mid T / F$

$F ::= \text{num} \mid (E)$

v3) Eliminăm *recursivitatea la stânga* \Rightarrow putem scrie direct cod

$E ::= T \text{ RestE}$

$\text{RestE} ::= \epsilon \mid + T \text{ RestE} \mid - T \text{ RestE}$

$T ::= F \text{ RestT}$

$\text{RestT} ::= \epsilon \mid * F \text{ RestT} \mid / F \text{ RestT}$

$F ::= \text{num} \mid (E)$

Expresii prefix și postfix (1)


nu necesită paranteze, subexpresiile reies din structură

Expresii **prefix**: operatorul *înaintea* operanzilor
implicit: la fel și în *subexpresii*

$E ::= \text{num} \mid \text{Op } E \ E$

$\text{Op} ::= + \mid - \mid * \mid /$

$* - 2 + 3 4 5 = (2 - (3 + 4)) * 5$



Putem scrie direct cod pornind de la această gramatică!

Expresii prefix și postfix (2)

Expresii *postfix*: operatorul *după* operanzi, la fel în subexpresii

$E ::= \text{num} \mid E \ E \ \text{Op}$


$\text{Op} ::= + \mid - \mid * \mid /$

$$\underbrace{2 \ 4 \ 5}_{\underbrace{- \ - \ 7}_{\underbrace{*}} \ = \ (2 - (4 - 5)) * 7}$$

Putem elimina recursivitatea la stânga:

$E ::= \text{num RestE}$

$\text{RestE} ::= \epsilon \mid E \ \text{Op RestE}$



Scrierile se pot obține prin traversarea arborelui expresiei:

în *preordine*: întâi operatorul, apoi subexpresiile (în același fel)

în *postordine*: întâi subexpresiile (în același fel), apoi operatorul