

Logică și structuri discrete
Limbaje regulate și automate

Marius Minea
marius@cs.upt.ro

<http://www.cs.upt.ro/~marius/curs/lsd/>

8 decembrie 2015

Un exemplu: automatul de cafea

acțiuni (utilizator): introdu *fisă*, apasă *buton*

răspuns (automat): *toarnă cafea*

După o acțiune *se întâmplă* ceva ?

buton nu

fisă (aparent) nu

fisă buton da

fisă a avut un efect *intern*: automatul a trecut în altă *stare*
(se *comportă altfel* la acțiunea *buton*)

fisă fisă buton buton dă două cafele ?

dacă da, câte fise poate ține minte ?

una sau mai multe, dar practic un număr *fin* ⇒ *stări finite*

Testăm cu diverse *secvențe de intrări*: corespunde specificației?

Putem *învăța* structura automatului (din comportament)

Testarea de conformanță și *învățarea*: importante în practică

Eliminarea comentariilor în C

Comentariu C: încadrat între /* și */ sau toată linia după //

Sursa nu are voie să se termine înăuntrul unui comentariu

Cum *recunoaștem* un comentariu ?

Cum *decidem* dacă să *acceptăm* o sursă corectă ?

Trebuie să *reținem* unde ne aflăm în prelucrare (*starea*)

în afara comentariului

înăuntrul comentariului

așteptând un posibil început de comentariu (după /)

așteptând un posibil sfârșit de comentariu (după *)

Acceptăm programul dacă în final, suntem în afara comentariului altfel *respingem* (nu acceptăm) programul

Desigur, sintaxa C are multe alte reguli în afară de comentarii.

Ce e un limbaj (formal)

Fie un *alfabet* Σ : o mulțime de *simboluri* (ex. caractere)

Un *cuvânt* finit peste alfabetul Σ e un sir de simboluri din Σ

$$a_1 a_2 \dots a_n \quad a_i \in \Sigma$$

Notăm cu Σ^* mulțimea tuturor cuvintelor *finite* peste alfabetul Σ

$$\Sigma^* = \{a_1 a_2 \dots a_n \mid a_i \in \Sigma\}$$

steaua Kleene: zero sau mai multe apariții
(în *expresii regulate*, vezi ulterior)

Important: Σ^* are cuvinte de lungime *nelimitată*, dar nu *infinite*

Un *limbaj formal* \mathcal{L} e o submulțime $\mathcal{L} \subseteq \Sigma^*$, definită după anumite *reguli*: gramatici, automate, expresii regulate, etc.

limbajul sirurilor de paranteze echibrate; al sirurilor palindrom;
al sirurilor de 0 și 1 care nu au trei 0 consecutivi; etc.

Automat finit deterministic (DFA)

Într-un automat trebuie să definim stările, trecerile dintr-o stare în alta (tranzitii), starea initială, și unde dorim să ajungem.

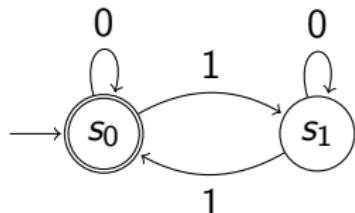
Automat finit deterministic: o mulțime de *stări* (unele acceptoare), o *stare initială*, și *tranzitii* în funcție de *simbolurile* de intrare.

Un automat finit e un tuplu cu 5 elemente (cvintuplu) $(\Sigma, S, s_0, \delta, F)$

- ▶ Σ e un *alfabet* finit nevid de *simboluri* de intrare
- ▶ S e o mulțime finită nevidă de *stări*
- ▶ $s_0 \in S$ e *starea initială*
- ▶ $\delta : S \times \Sigma \rightarrow S$ e *funcția de tranzitie*
(pentru fiecare stare și intrare, dă starea următoare)
- ▶ $F \subseteq S$ e mulțimea stărilor *acceptoare*
(unde dorim să ajungem)

Exemple de automate deterministe

automat de paritate: acceptă siruri de 0 și 1 cu număr par de 1



sau ca tabelă de tranziții

	0	1
s_0	s_0	s_1
s_1	s_1	s_0

s_0 e stare inițială

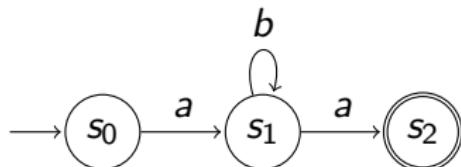


și acceptoare

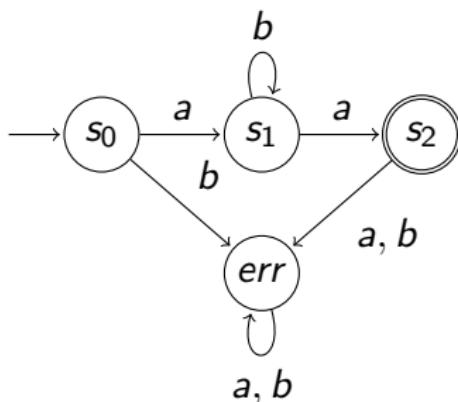


în același timp

automat care acceptă cuvinte cu oricărăți de b (incl. 0) între doi a



ca δ să fie definită peste tot
e necesară încă o stare err
uneori în practică se omite



Limbajul acceptat de un automat

Notăm $\epsilon \in \Sigma^*$ cuvântul *vid* (fără niciun simbol).

Definim inductiv o funcție de tranzitie δ^* cu intrări *cuvinte*: în ce stare ajunge automatul pentru un cuvânt dat la intrare? pentru orice $s \in S$:

$$\delta^*(s, \epsilon) = s \quad \text{cuvânt vid: nu face nimic}$$

$$\delta^*(s, a_1 \dots a_n) = \delta^*(\delta(s, a_1), a_2 \dots a_n) \quad \text{pentru } n > 0$$

Altfel spus, $\delta^*(s_0, a_1 \dots a_n) = \delta^*(s_1, a_2 \dots a_n)$ cu $s_1 = \delta(s_0, a_1)$ obținem starea s_1 după intrarea a_1 , și aplicăm δ^* pe sirul rămas

Automatul *acceptă* cuvântul $w \in \Sigma^*$ dacă și numai dacă $\delta^*(s_0, w) \in F$ (cuvântul *duce* automatul într-o stare *acceptoare*)

Cum reprezentăm un automat ?

Matrice $S \times \Sigma$ cu elemente din S
(pentru fiecare stare și intrare, starea următoare)

reprezintă *explicit* fiecare combinație

	0	1
s_0	s_0	s_1
s_1	s_1	s_0

Sau: un *dicționar* care dă pentru fiecare stare funcția de tranziție
reprezentată tot ca un *dicționar* (intrare, stare)

Dacă într-o stare multe simboluri duc în aceeași stare următoare,
asociem fiecărei stări:

un dicționar (intrare, stare)

o stare următoare *implicită* (pentru celelalte intrări)

Automate cu ieșiri

numite și *traductoare* (engl. *transducer*)

scopul: generează răspunsuri/ieșiri; nu au multime acceptoare F

în plus: un *alfabet de ieșire* Ω și o *funcție de ieșire* g

automate de tip *Moore*

ieșirea e funcție de *stare*: $g : S \rightarrow \Omega$

automate de tip *Mealy*

ieșirea e funcție de *stare* și *intrare* $g : S \times \Sigma \rightarrow \Omega$

folosite pentru a modela *circuite sevențiale*

Intersecția, reuniunea și complementul limbajelor

Un limbaj recunoscut de un automat se numește *limbaj regulat*
vom vedea că se poate exprima prin *expresii regulate*

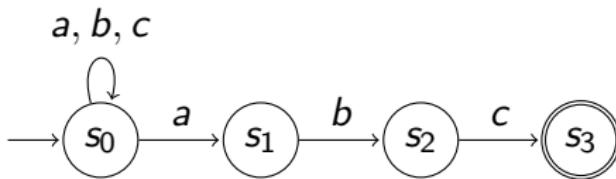
Automatul pentru *intersecția* a două limbaje $\mathcal{L}_1 \cap \mathcal{L}_2$
(numit uzual automatul produs)
tranzitionează *simultan* în ambele automate
acceptă dacă *ambele* acceptă:

Automatul pentru *reuniunea* a două limbaje $\mathcal{L}_1 \cup \mathcal{L}_2$
tranzitionează *simultan* în ambele automate (ca mai sus)
acceptă dacă *cel puțin unul* acceptă

Automatul pentru *complement* $\bar{\mathcal{L}}$
acceptă dacă automatul original nu acceptă

Automate finite nedeterministe (NFA)

Exemplu: toate sirurile de a, b, c care se termină în abc



Din s_0 , primind a , automatul poate

- încerca să vadă dacă vor mai fi exact 3 simboluri (trece în s_1)
 - rămâne în s_0 (presupunând că urmează mai mult de 3)
- ⇒ automatul poate urma *una din mai multe* căi

Un NFA acceptă dacă există o alegere ducând în stare acceptoare.

Funcția de tranziție e acum $\delta : S \times \Sigma \rightarrow \mathcal{P}(S)$

dă o *multime de stări* în care poate trece automatul

Avantaje:

uneori se scrie mai ușor (permite să “ghicim” tranziția bună)
când specificăm un sistem, permite o alegere la implementare

Conversie NFA-DFA

Fie un NFA $M = (\Sigma, S, s_0, \delta, F)$. Construim un DFA echivalent.

Reținem la orice pas *multimea de stări* în care s-ar putea afla M
⇒ noua multime de stări va fi $S' = \mathcal{P}(S)$

în cel mai rău caz, poate fi exponential în dimensiunea inițială
 $|\mathcal{P}(S)| = 2^{|S|}$

Obținem $M' = (\Sigma, S', s_0, \delta', F')$ cu

$$S' = \mathcal{P}(S)$$

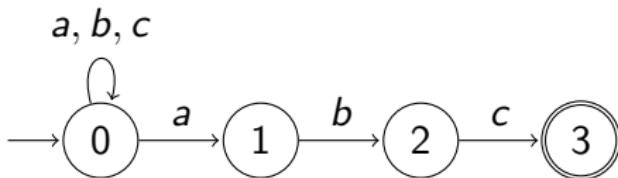
$$\delta'(q, a) = \bigcup_{s \in q} \delta(s, a) \quad (\text{pentru fiecare stare } s \in q \text{ cu } q \in \mathcal{P}(S),$$

reunim multimile stărilor în care se ajunge pe simbolul a)

$$F' = \{s \in S' \mid s \cap F \neq \emptyset\}$$

(multimea stărilor care au o stare acceptoare din F)

Conversie NFA-DFA (exemplu)

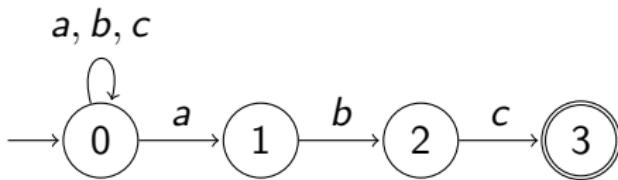


Când obținem o nouă multime adăugăm o linie la tabel.

Scriem tabelul de tranziție cu multimea stărilor în care se trece pe fiecare simbol

	a	b	c
{0}	{0, 1}	{0}	{0}

Conversie NFA-DFA (exemplu)

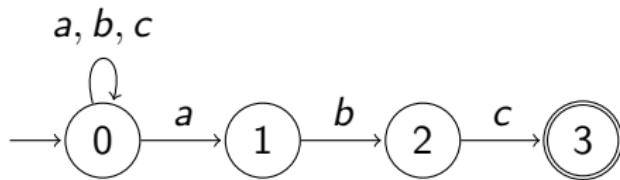


Când obținem o nouă multime adăugăm o linie la tabel.

Scriem tabelul de tranziție cu multimea stărilor în care se trece pe fiecare simbol

	a	b	c
{0}	{0, 1}	{0}	{0}
{0, 1}	{0, 1}	{0, 2}	{0}

Conversie NFA-DFA (exemplu)

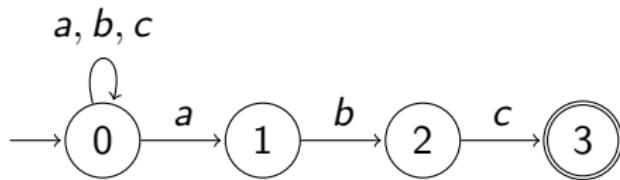


Când obținem o nouă multime adăugăm o linie la tabel.

Scriem tabelul de tranziție cu multimea stărilor în care se trece pe fiecare simbol

	a	b	c
{0}	{0, 1}	{0}	{0}
{0, 1}	{0, 1}	{0, 2}	{0}
{0, 2}	{0, 1}	{0}	{0, 3}

Conversie NFA-DFA (exemplu)

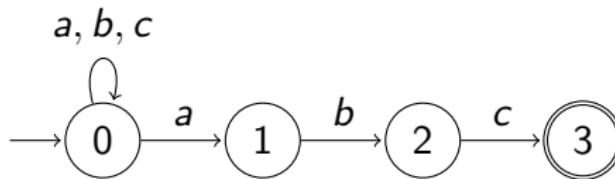


Când obținem o nouă multime adăugăm o linie la tabel.

Scriem tabelul de tranziție cu multimea stărilor în care se trece pe fiecare simbol

	a	b	c
{0}	{0, 1}	{0}	{0}
{0, 1}	{0, 1}	{0, 2}	{0}
{0, 2}	{0, 1}	{0}	{0, 3}
{0, 3}	{0, 1}	{0}	{0}

Conversie NFA-DFA (exemplu)

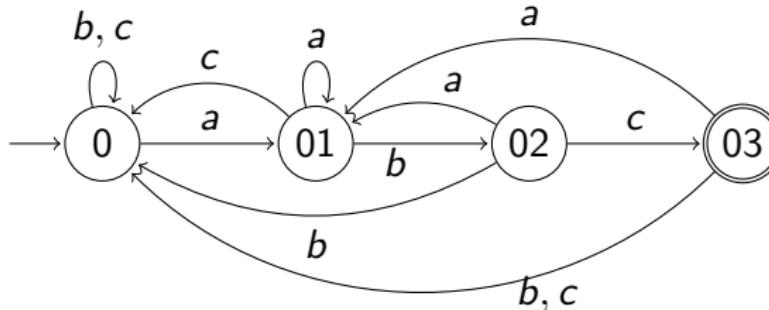


Când obținem o nouă multime adăugăm o linie la tabel.

Scriem tabelul de tranziție cu multimea stărilor în care se trece pe fiecare simbol

	a	b	c
{0}	{0, 1}	{0}	{0}
{0, 1}	{0, 1}	{0, 2}	{0}
{0, 2}	{0, 1}	{0}	{0, 3}
{0, 3}	{0, 1}	{0}	{0}

Fiecare multime obținută devine o stare în DFA-ul rezultat



Stările acceptoare sunt cele care conțin o stare acceptoare din automatul inițial.

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

	a	d
{1}	{2, 4}	{5}

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}
{1, 3, 5, 7}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}
{1, 3, 5, 7}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}
{2, 4, 6, 8}	{1, 3, 5, 7, 9}	{2, 4, 6, 8}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}
{1, 3, 5, 7}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}
{2, 4, 6, 8}	{1, 3, 5, 7, 9}	{2, 4, 6, 8}
{1, 3, 7, 9}	{2, 4, 6, 8}	{5}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonală

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}
{1, 3, 5, 7}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}
{2, 4, 6, 8}	{1, 3, 5, 7, 9}	{2, 4, 6, 8}
{1, 3, 7, 9}	{2, 4, 6, 8}	{5}
{1, 3, 5, 7, 9}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}

Un alt exemplu: mutări după o regulă

1	2	3
4	5	6
7	8	9

stare initială: 1

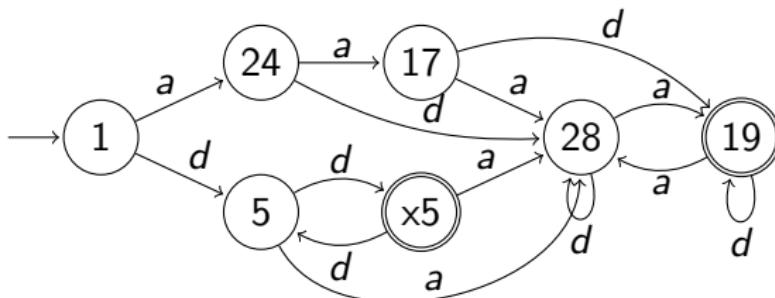
stare finală: 9

$$\Sigma = \{a, d\}$$

a: mută adiacent

d: mută diagonal

	a	d
{1}	{2, 4}	{5}
{2, 4}	{1, 3, 5, 7}	{2, 4, 6, 8}
{5}	{2, 4, 6, 8}	{1, 3, 7, 9}
{1, 3, 5, 7}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}
{2, 4, 6, 8}	{1, 3, 5, 7, 9}	{2, 4, 6, 8}
{1, 3, 7, 9}	{2, 4, 6, 8}	{5}
{1, 3, 5, 7, 9}	{2, 4, 6, 8}	{1, 3, 5, 7, 9}



$$17 = \{1, 3, 5, 7\}$$

$$28 = \{2, 4, 6, 8\}$$

$$x5 = \{1, 3, 7, 9\}$$

$$19 = \{1, 3, 5, 7, 9\}$$

Putem exprima mai concis definiția unui limbaj?

Un limbaj = o mulțime de cuvinte peste un alfabet

Adesea suntem interesați în cuvinte cu structură simplă:

- un întreg: o secvență de cifre, eventual cu semn

- un real: parte întreagă + parte zecimală (una din ele optională), exponent optional

- un identificator: litere, cifre, _ începând cu literă sau _

- fișiere cu numele 01-titlu.mp3, 02-alttitlu.mp3, ...

Unele limbi pot fi recunoscute eficient de *automate finite*

dar scrierea automatului ia efort

⇒ se poate face mai simplu ?

Operații pe limbaje

Reuniunea, intersecția și complementul limbajelor regulate sunt limbaje regulate

Mai putem defini:

Concatenarea limbajelor

$$L_1 \cdot L_2 = \{w_1 w_2 \mid w_1 \in L_1, w_2 \in L_2\}$$

Închiderea Kleene (repetiția)

$$L^* = \{w \mid \exists n \in \mathbb{N}. w = w_1 w_2 \dots w_n, w_i \in L\}$$

nu repetiția același sir, ci concatenarea *oricăror* siruri

luând $n = 0$, rezultă $\epsilon \in L^*$ pentru orice $L \neq \emptyset$

ϵ reprezintă *sirul vid* (niciun simbol, lungime 0)

Expresii regulate: definiție formală

O expresie regulată descrie un limbaj (regulat).

O expresie regulată peste un alfabet Σ e fie:

3 cazuri de bază:

\emptyset

limbajul vid

ϵ

denotă limbajul $\{\epsilon\}$ (cu sirul vid)

a

denotă limbajul $\{a\}$ cu $a \in \Sigma$

3 cazuri recursive: date e_1, e_2 expresii regulate, și următoarele sunt:

$(e_1 + e_2)$

reuniunea limbajelor

în practică, notată adesea $e_1|e_2$ (alternativă, "sau")

$(e_1 \cdot e_2)$

concatenarea limbajelor

e_1^*

închiderea Kleene a limbajului

Reguli de scriere și exemple

Omitem paranteze cănd sunt clare din relațiile de precedență
cel mai prioritar: *, apoi concatenare și apoi reuniune +
punctul pentru concatenare se omite

În practică se mai folosesc abrevierile

$e?$ pentru $e + \epsilon$ (e, optional)

e^+ pentru $e^* \setminus \epsilon$ (e, cel puțin o dată)

$(0 + 1)^*$ multimea tuturor sirurilor din 0 sau 1

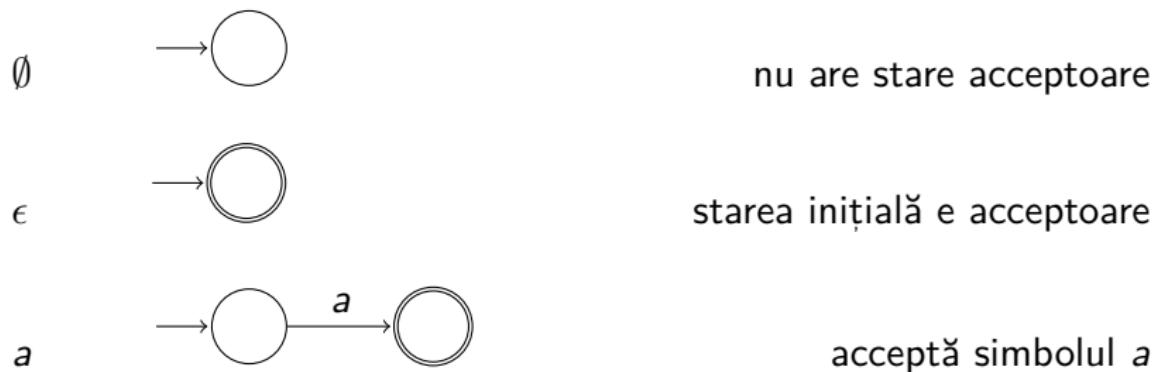
$(0 + 1)^*0$ ca mai sus, încheiat cu 0 (numere pare în binar)

$1(0 + 1)^* + 0$ numere binare, fără zerouri initiale inutile

Orice expresie regulată e recunoscută de un automat

Construim prin *inducție structurală*

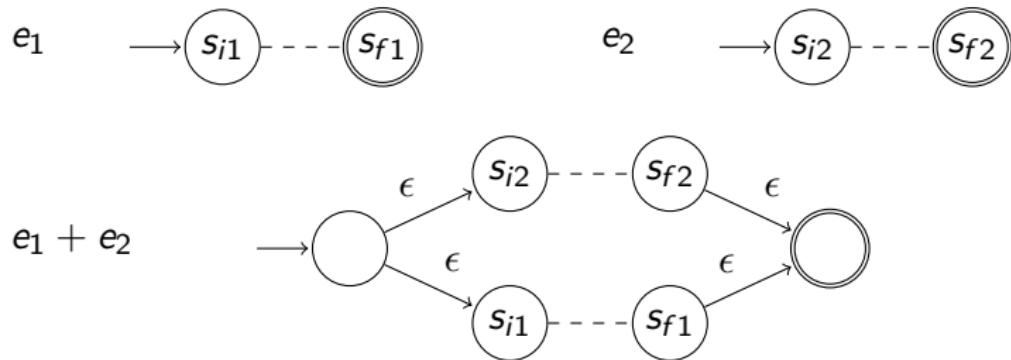
Pentru cazurile de bază



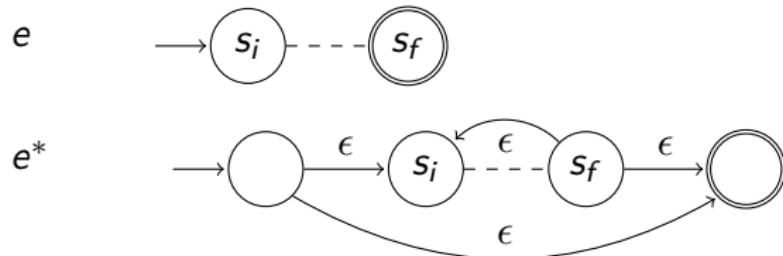
În celelalte trei cazuri, *combinăm* automatele limbajelor date
rezultă un *automat finit nedeterminist* cu tranzițiile

Conversia expresie regulată → automat

Construcția pentru reuniune

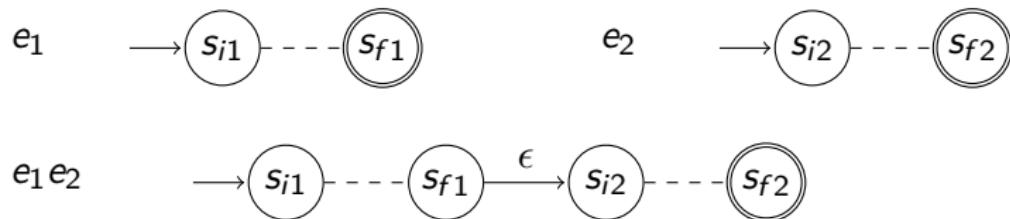


Construcția pentru închiderea Kleene



Conversia expresie regulată → automat

Construcția pentru concatenare



În general, nu putem contopi s_{f1} și s_{i2} : ajunși în s_{f1} nu avem voie să revenim în e_1 .

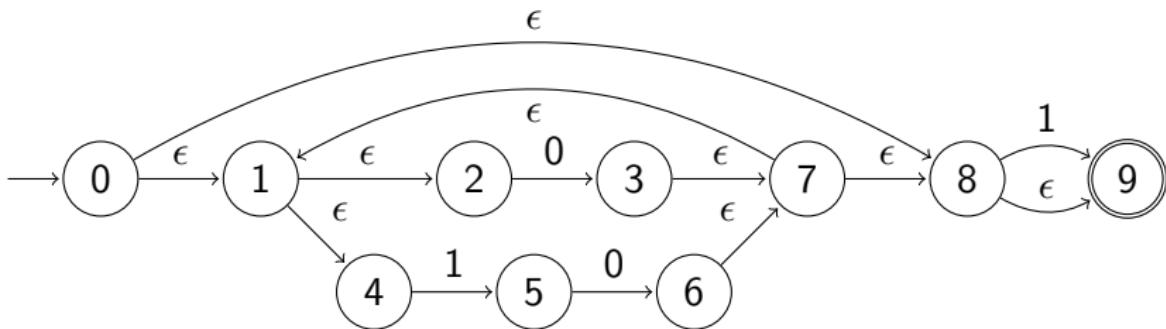
Însă construcțiile de până acum asigură:

- o *unică* stare initială, în care nu se revine
- o *unică* stare acceptoare, din care nu ies tranziții

Atunci putem contopi la concatenare capetele lui e_1 și e_2 .

Conversie din expresie regulată în automat

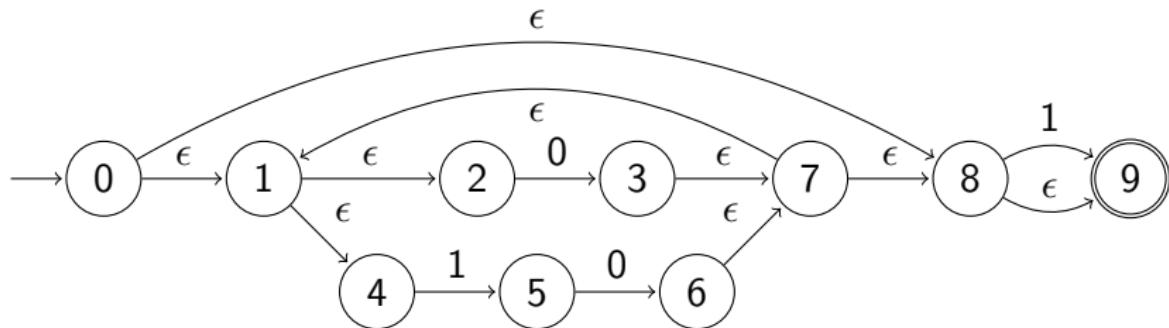
Fie expresia $(0+10)^*(1+\epsilon)$. Construim (comasând pașii triviali):



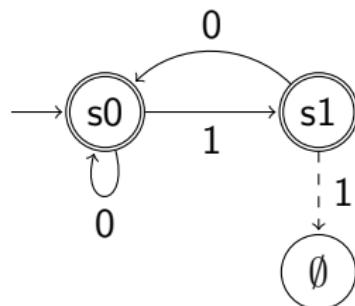
O *tranzitie ϵ* se face spontan, fără a consuma un simbol de intrare
⇒ ajuns într-o stare s , e ca și ajuns în orice stare s' legată de s
doar prin ϵ -tranzitii (*închiderea tranzitivă* a relației definite de ϵ)

Deci, aflat în 0, e ca și cum s-ar afla în 1, 2, 4, 8 sau 9
Aflat în 7, e ca și cum s-ar afla în 1, 2, 4, 8, 9

Conversie din NFA cu tranziții ϵ în DFA



	0	1
012489	1234789	59
1234789	1234789	59
59	1246789	\emptyset
1246789	1234789	59



Liniile 1, 2 și 4 au destinații identice \Rightarrow stările sunt echivalente.
 \Rightarrow automat cu doar două stări (ignorând starea de eroare \emptyset)

Conversia din automat în expresie regulată

Dacă sunt mai multe noduri acceptoare, adaugăm un nod acceptor unic (cu tranziții ϵ spre el)

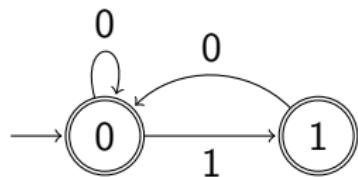
Eliminăm pe rând fiecare nod în afară de cel inițial și acceptor:
pentru orice nod intermediar i de eliminat

pentru orice pereche (s, d)

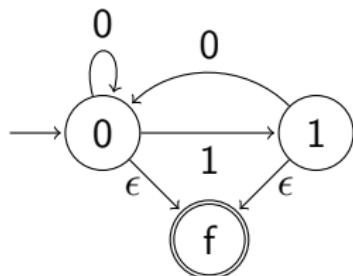
adaugă la muchia $s \rightarrow d$ limbajul $L_{si}L_{ii}^*L_{id}$

Conversie din automat în expresie regulată

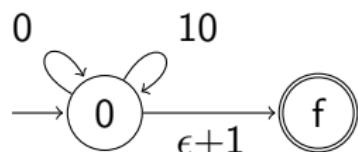
Şiruri de 0 și 1 care nu au doi 1 consecutivi
pe 1, trece în stare cu tranziție doar pe 0



Ambele stări sunt acceptoare \Rightarrow adăugăm o unică stare acceptoare



Eliminăm 1:
 $0 \xrightarrow{10} 0$
 $0 \xrightarrow{1\epsilon} f$



Obținem astfel limbajul $(0+10)^*(1+\epsilon)$

Minimizarea automatelor

Două stări s_1 și s_2 pot fi *deosebite* dacă există un cuvânt w care dintr-una din stări conduce la o stare acceptoare, și din celalătă, nu

$$\delta^*(s_1, w) \in F \neq \delta^*(s_2, w) \in F$$

Două stări care nu pot fi deosebite sunt *echivalente*
⇒ pot fi înlocuite cu o singură stare

Un DFA e *minimal* dacă nu există un automat cu mai puține stări care acceptă același limbaj.

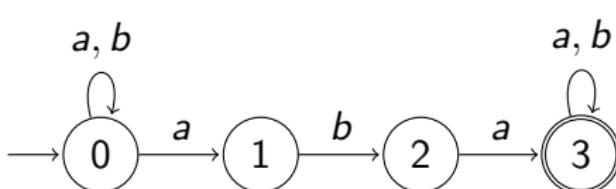
Diverse *algoritmi de minimizare* (ex. Hopcroft-Ullman, Moore)

initial, partiție cu 2 blocuri: $F, S \setminus F$ (stări acceptoare sau nu)
(o împărțire în *potențiale* clase de echivalență)

desparte un bloc din partiție dacă pe un simbol, stările nu trec
toate în același bloc din partiție (pot fi deosebite)

Conversie NFA-DFA și minimizare (exemplu)

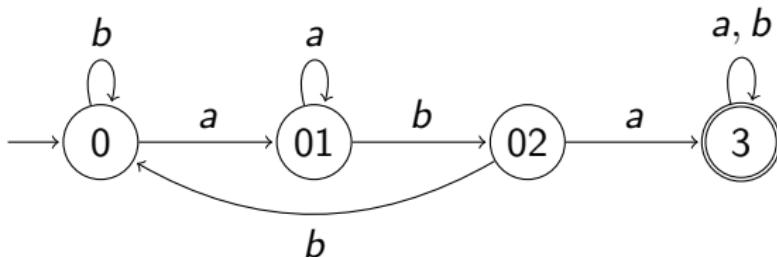
Cuvinte din a, b cu subșir aba : "ghicim" când începe subșirul dorit



	a	b
0	01	0
01	01	02
02	013	0
013	013	023
023	013	03
03	013	03

Stările care conțin 3 (stare acceptoare) sunt **acceptoare**.

Aici, ele trec tot timpul în stări acceptoare, deci sunt **echivalente** (caz simplu), și le putem comoda într-o singură stare (numită 3).



Recapitulare

Un automat determinist definește un *limbaj* acceptat.

Un astfel de limbaj se numește *limbaj regulat*.

El poate fi exprimat și printr-o *expresie regulată*.

Intersecția, reuniunea, și complementarea limbajelor regulate produc limbaje regulate

(deci pot fi recunoscute de automate finite)

Automatele finite nedeterministe se pot transforma în deterministe

(deci recunosc tot limbaje regulate)

dar numărul de stări poate crește exponential

Automatele finite pot fi *minimizeate*, comasând *stările echivalente*.

Automatele deterministe și nedeterministe și expresiile regulate au aceeași putere expresivă (descriu limbaje regulate).