

Regularni izrazi i konačni automati

Miloš Stanojević

Matematička gimnazija, NEDELJA INFORMATIKE

2. april 2015.

Uvod: mnoštvo primena

- Funkcija `grep` u komandnoj liniji (Unix-based sistemi);
- Word-search u text editorima;
- Leksička analiza u kompajleru i mnoge druge!

Alfabeti

- **Alfabet** je konačan skup Σ , čije elemente zovemo **simboli**;
- Svaki skup može biti alfabet, dokle god je konačan;
- Primeri:
 - $\Sigma_1 = \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$
 - $\Sigma_2 = \{a, b, c, \dots, x, y, z\}$
 - slova azbuke
- Ne-primer:
 - $\mathbb{N} = \{0, 1, 2, 3, \dots\}$

Stringovi

- **String dužine** n nad alfabetom Σ , je uređena n -torka elemenata iz Σ , napisana bez znakova interpunkcije;
- Primer: Neki stringovi nad $\Sigma = \{a, b, c\}$ su: $a, ab, aac, bbac\dots$
- Σ^* je skup svih stringova nad skupom Σ ;
- ε je jedinstveni **prazan string** za svako Σ .

Konkatenacija stringova

- **Konkatenacija** (ili spajanje) dva stringa $u, v \in \Sigma^*$ je string uv , koji dobijamo kada spojimo kraj prvog sa početkom drugog stringa;
- Primer: $u = ab, v = ra, w = cad$, tada je $vu = raab$, $uw = abab$ i $wv = cadra$;
- Ovo generalizujemo u spajanje dva ili više stringova (npr. $vwuv = abracadabra$).

Regularni izrazi nad alfabetom Σ

- svaki simbol $a \in \Sigma$ je regularni izraz;
- ε je regularni izraz;
- \emptyset je regularni izraz;
- ukoliko su r i s regularni izrazi, tada je i $(r|s)$ regularni izraz;
- ukoliko su r i s regularni izrazi, tada je i rs regularni izraz;
- ukoliko je r regularni izrazi, tada je i $(r)^*$ regularni izraz;

Svaki regularni izraz gradi se induktivno, *konačnom* primenom ovih pravila. (**NB** pretpostavljamo da ε , \emptyset , $($, $)$, i $*$ nisu simboli u Σ .)

Prednost operacija: dogovor

- $-^*$ ima veći prioritet od $- -$;
- $- -$ ima veći prioritet od $-|-$;
- Primer: $r|st^*$ znači $(r|s(t)^*)$, a ne $(r|s)(t)^*$ ili $((r|st))^*$

Uparivanje stringova i regularnih izraza

- u odgovara $a \in \Sigma \iff u = a$;
- u odgovara $\varepsilon \iff u = \varepsilon$;
- ni jedan string ne odgovara \emptyset ;
- u odgovara $r|s \iff u$ odgovara r ili u odgovara s ;
- u odgovara $rs \iff$ se može izraziti kao konkatencija dva stringa $u = vw$, gde v odgovara r i w odgovara s ;
- u odgovara $r^* \iff$ je $u = \varepsilon$ ili se u može izraziti kao konkatencija dva ili više stringova, od kojih svaki odgovara r .

Primeri uparivanja, $\Sigma = \{0, 1\}$

- $0|1$ odgovaraju svi simboli u Σ ;
- $1(0|1)^*$ odgovaraju svi stringovi u Σ^* koji počinju sa '1';
- $((0|1)(0|1))^*$ odgovaraju svi stringovi parne dužine u Σ^* ;
- $(0|1)^*(0|1)^*$ odgovaraju svi stringovi u Σ^* ;
- $(\varepsilon|0)(\varepsilon|1)|11$ odgovaraju samo stringovi $\varepsilon, 0, 1, 01$ i 11 ;
- $\emptyset|1|0$ odgovara samo 0.

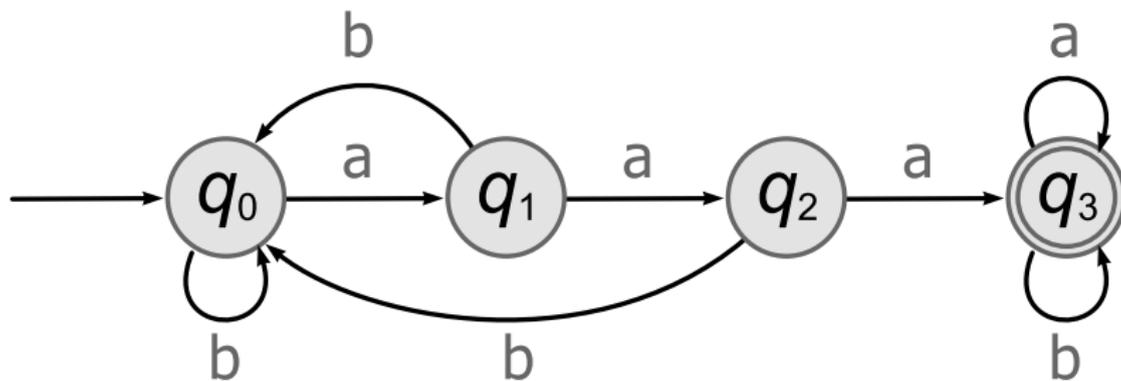
Jezici i regularni izrazi

- (Formalni) **jezik** L nad alfabetom Σ je neki podskup skupa Σ^* ;
- **Jezik koji određuje regularni izraz** r nad Σ definiše se kao:

$$L(r) \stackrel{\text{def}}{=} \{u \in \Sigma^* \mid u \text{ odgovara } r\}$$

- Dva regularna izraza r i s (nad istim alfabetom Σ) su **ekvivalentni** akko su $L(r)$ i $L(s)$ jednaki skupovi (odnosno imaju tačno sve iste elemente).

Primer konačnog automata



- Stanja: q_0, q_1, q_2, q_3 ;
- Ulazni simboli: a, b ;
- Prelazi: pogledati strelice na slici;
- Početno stanje: q_0 ;
- Stanje prihvatanja: q_3 .

Jezici i konačni automati

$L(M)$, **jezik koji prihvata konačni automat** M sastoji se od svih stringova u nad njegovim alfabetom ulaznih simbola koji zadovoljavaju $q_0 \xrightarrow{u}_* q$, gde je q_0 početno stanje i q neko stanje prihvatanja. Ovde

$$q_0 \xrightarrow{u}_* q$$

znači da za neko $u = a_1 a_2 \dots a_n$ postoje neka (ne obavezno različita) stanja $q_1, q_2, \dots, q_n = q$, između kojih su prelazi oblika

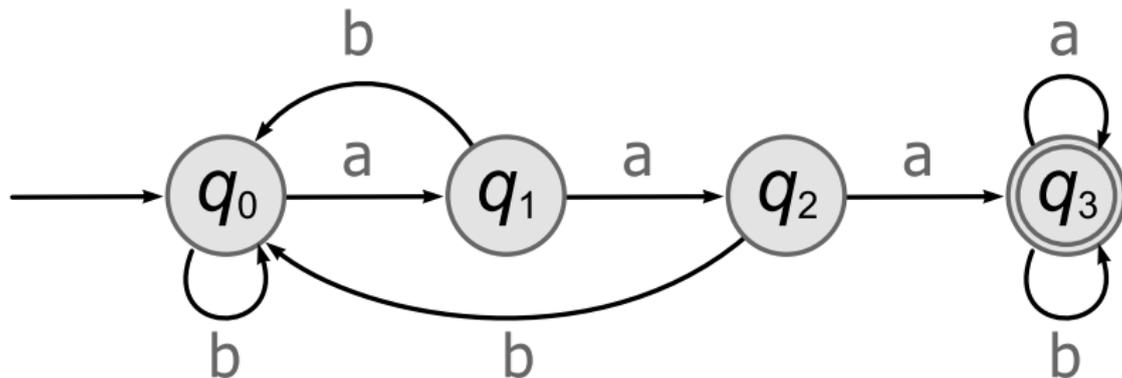
$$q_0 \xrightarrow{a_1} q_1 \xrightarrow{a_2} q_2 \xrightarrow{a_3} \dots \xrightarrow{a_n} q_n = q.$$

NB

slučaj $n = 0$: $q \xrightarrow{\epsilon}_* q'$ akko $q = q'$

slučaj $n = 1$: $q \xrightarrow{a}_* q'$ akko $q \xrightarrow{a} q'$.

Primeri



- $q_0 \xrightarrow{aaab}_* q_3 \implies aaab \in L(M)$
- $(q_0 \xrightarrow{abaa}_* q \iff q = q_2) \implies abaa \notin L(M)$
- $(q_2 \xrightarrow{baaa}_* q \iff q = q_3) \implies$ nemamo zaključak o $L(M)$
- regularni izraz?

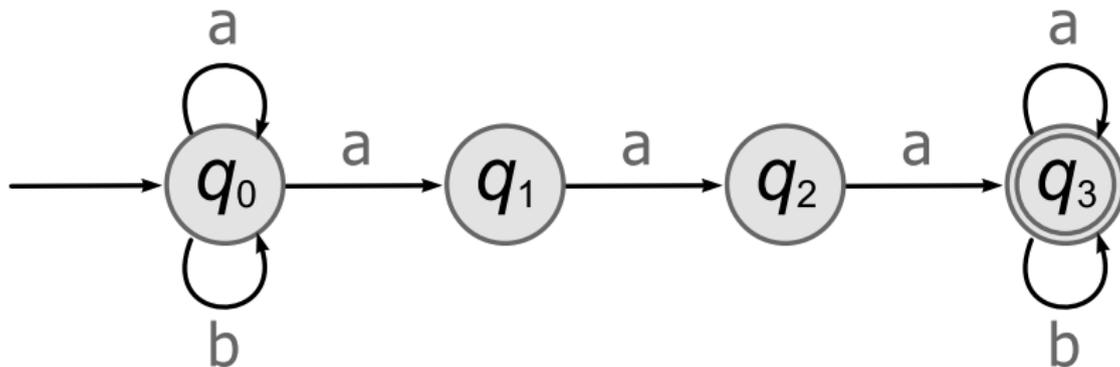
Ne-Deterministički konačni automat

Nedeterministički konačni automat (NFA), M , definisan je sa:

- konačnim skupom **stanja** $Stanja_M$;
- konačnim skupom Σ_M (**alfabet ulaznih simbola**)
- za svako $q \in Stanja_M$ i za svako $a \in \Sigma_M$, podskupom $\Delta_M(q, a) \subseteq Stanja_M$ (skup stanja do kojih se može doći sa jednim **prelazom** pošavši od q)
- elementom $s_M \in Stanja_M$ (**početno stanje**)
- podskupom $Prihvata_M \subseteq Stanja_M$ (**stanja prihvatanja**)

Primer: NFA

Ulazni alfabet: $\{a, b\}$



Jezik koji ovaj automat prihvata isti je kao i jezik automata iz prethodnog primera, naime

$$\{u \in \{a, b\}^* \mid u \text{ sadrži tri uzastopna } a\}$$

Deterministički konačni automat

Deterministički konačni automat (DFA) definiše se kao NFA M sa svojstvom da za svako $q \in Stanja_M$ i $a \in \Sigma_M$, konačni skup $\Delta_M(q, a)$ sarži tačno jedan element, koji zovemo $\delta_M(q, a)$.

Zato su prelazi u M u ovom slučaju definisani **funkcijom sledećeg stanja**, δ_M , koja preslikava svaki (stanje, simbol)-par (q, a) u jedinstveno stanje $\delta_M(q, a)$ do kojeg se od q dolazi prelazom obeleženim sa a :

$$q \xrightarrow{a} q' \quad \text{akko} \quad q' = \delta_M(q, a)$$

Nedeterministički konačni automat sa ε -prelazima

Nedeterministički konačni automat sa ε -prelazima (NFA^ε) definiše se kao NFA M , sa dodatnom binarnom relacijom.

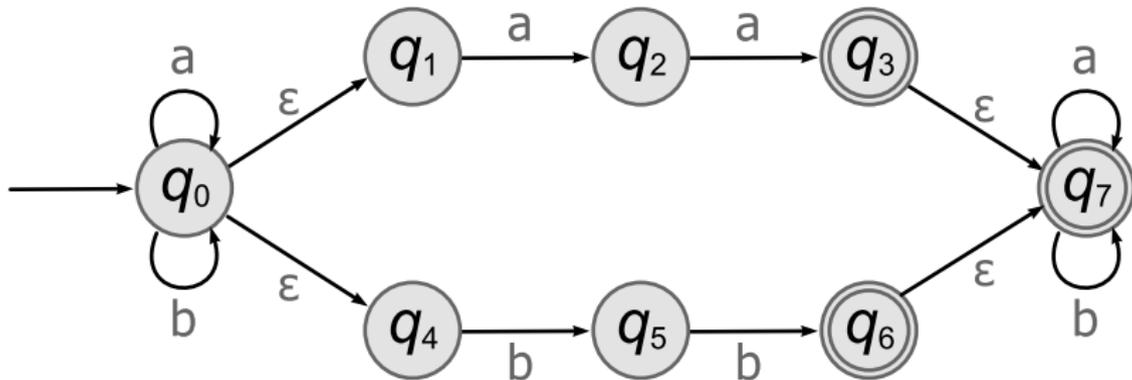
Ta relacija zove se **ε -prelaz**, definisana je na skupu Stanja_M i pišemo

$$q \xrightarrow{\varepsilon} q'$$

da bismo naznačili da je par stanja (q, q') u ε -relaciji.

Primer: NFA^ϵ

Ulazni alfabet: $\{a, b\}$

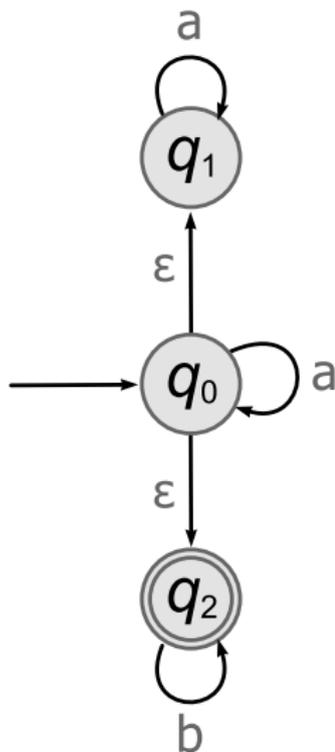


Jezik koji prihvata NFA^ε

$L(M)$, **jezik koji prihvata NFA^ε** M sastoji se od svih stringova u nad alfabetom Σ_M ulaznih simbola koji zadovoljavaju $q_0 \xRightarrow{u} q$ gde je q_0 početno, a q neko stanje prihvatanja. Ovde definišemo operaciju $\cdot \xRightarrow{\bar{}} \cdot$ na sledeći način:

- $q \xRightarrow{\varepsilon} q'$ akko $q = q'$, odnosno postoji sekvenca $q \xrightarrow{\varepsilon} \dots q'$ od jednog ili više ε -prelaza u M od q do q'
- $q \xRightarrow{a} q'$ (za $a \in \Sigma_M$) akko $q \xRightarrow{\varepsilon} \cdot \xrightarrow{a} \cdot \xRightarrow{\varepsilon} q'$
- $q \xRightarrow{ab} q'$ (za $a, b \in \Sigma_M$) akko $q \xRightarrow{\varepsilon} \cdot \xrightarrow{a} \cdot \xRightarrow{\varepsilon} \cdot \xrightarrow{b} \cdot \xRightarrow{\varepsilon} q'$

Primer podskup konstrukcije



δ_{PM}	a	b
\emptyset	\emptyset	\emptyset
$\{q_0\}$	$\{q_0, q_1, q_2\}$	$\{q_2\}$
$\{q_1\}$	$\{q_1\}$	\emptyset
$\{q_2\}$	\emptyset	$\{q_2\}$
$\{q_0, q_1\}$	$\{q_0, q_1, q_2\}$	$\{q_2\}$
$\{q_0, q_2\}$	$\{q_0, q_1, q_2\}$	$\{q_2\}$
$\{q_1, q_2\}$	$\{q_1\}$	$\{q_2\}$
$\{q_0, q_1, q_2\}$	$\{q_0, q_1, q_2\}$	$\{q_2\}$

Bitna teorema

Teorema. Za svaku $NFA^\epsilon M$ postoji DFA PM sa istim alfabetom, skupom ulaznih simbola i koja prihvata sve iste stringove kao i M , odnosno važi $L(PM) = L(M)$.

Dakle, na osnovu ove teoreme PM je definisana sa:

- $Stanja_{PM} \stackrel{\text{def}}{=} \{S \mid S \subseteq Stanja_M\}$
- $\Sigma_{PM} \stackrel{\text{def}}{=} \Sigma_M$
- $S \xrightarrow{a} S'$ je u PM akko $S' = \delta_{PM}(S, a)$, gde je $\delta_{PM}(S, a) \stackrel{\text{def}}{=} \{q' \mid (\exists q \in S)(q \xrightarrow{a} q' \text{ u } M)\}$
- $s_{PM} \stackrel{\text{def}}{=} \{q \mid s_M \xrightarrow{\epsilon} q\}$
- $Prihvata_M \stackrel{\text{def}}{=} \{S \in Stanja_{PM} \mid (\exists q \in S)(q \in Prihvata_M)\}$

Klejniva teorema

Definicija. Jezik je **regularan** akko ukoliko neki deterministički konačni automat prihvata sve njegove stringove.

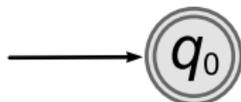
Klejniva teorema

- (a) Za svaki regularni izraz r , $L(r)$ je regularni jezik.
- (b) Obrnuto, svaki regularni jezik je forme $L(r)$, za neki regularni izraz r .

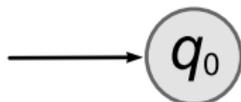
NFA-ovi atomskih izraza



prihvata samo jedno-simbolni string a

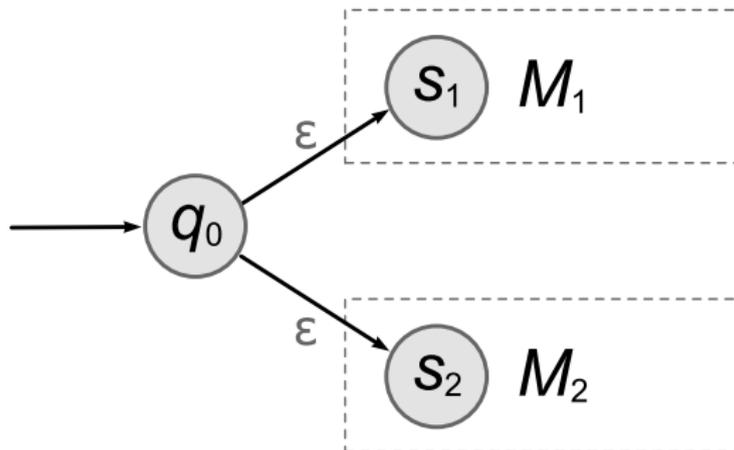


prihvata samo prazan string, ε



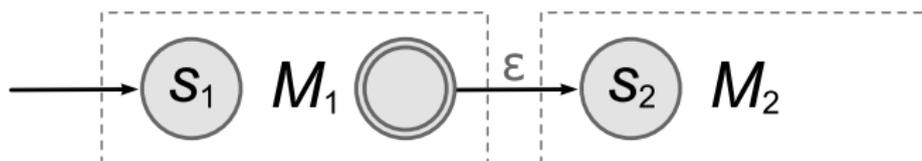
ne prihvata ni jedan string

$Union(M_1, M_2)$



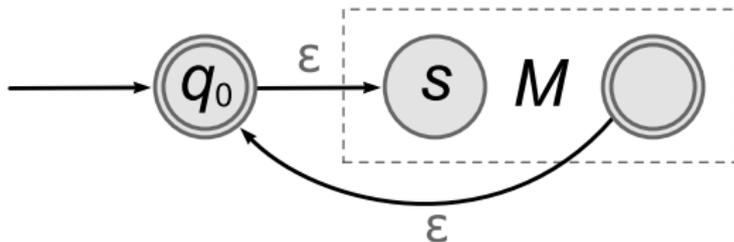
Skup stanja prihvatanja je unija $Prihvata_{M_1}$ i $Prihvata_{M_2}$.

$Concat(M_1, M_2)$



Skup stanja prihvatanja je unija $Prihvata_{M_2}$.

$Star(M)$



Skup stanja prihvatanja je unija $Prihvata_{M_1}$ i $Prihvata_{M_2}$.

Primer: $(a|b)^*a$

korak: 1

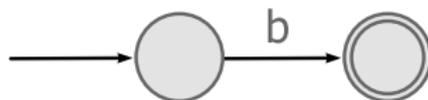
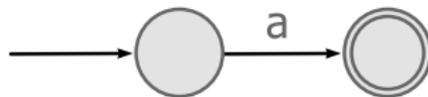
pravimo NFA^ϵ za izraz: a



Primer: $(a|b)^*a$

korak: 2

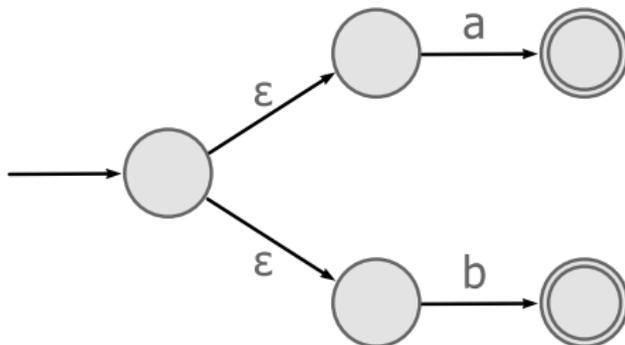
pravimo NFA^ϵ za izraz: a i b (odvojeno)



Primer: $(a|b)^*a$

korak: 3

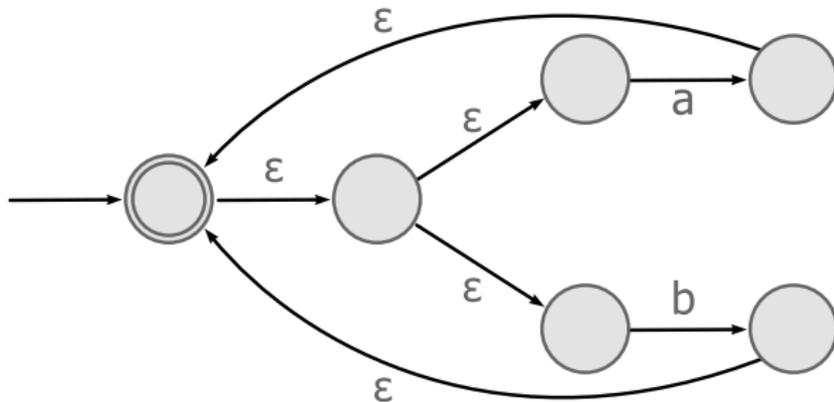
pravimo NFA^ϵ za izraz: $a|b$



Primer: $(a|b)^*a$

korak: 4

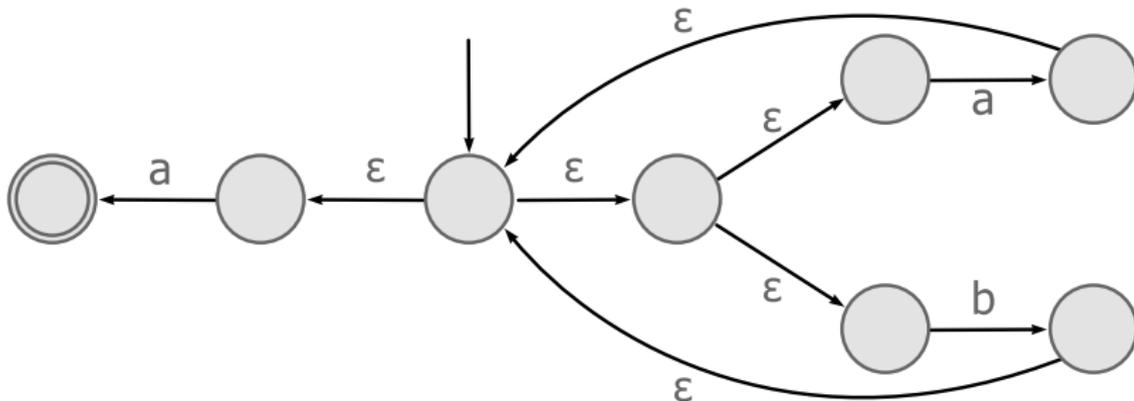
pravimo NFA^ϵ za izraz: $(a|b)^*$



Primer: $(a|b)^*a$

korak: 5

pravimo NFA^ϵ za izraz: $(a|b)^*a$



Bitna lema

Lema. Za datu NFA M , za svaki podskup $Q \subseteq Stanja_M$ i svaki par stanja $q, q' \in Stanja_M$, postoji regularni izraz $r_{q,q'}^Q$ koji zadovoljava

$$L(r_{q,q'}^Q) = \{u \in (\Sigma_M)^* \mid q \xrightarrow{u}_* q' \text{ je u } M \text{ sa svim među-} \quad (1)$$

stanjima sekvence prelaza u $Q\}$

Stoga, $L(M) = L(r)$, gde je $r = r_1 | \dots | r_k$ i

k = broj svih stanja prihvatanja,

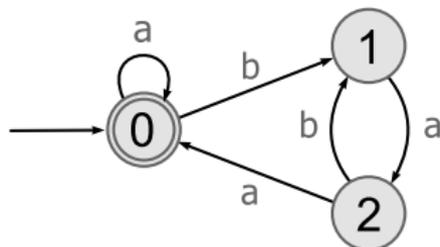
$r_i = r_{s,q_i}^Q$, gde je $Q = Stanja_M$,

s = početno stanje,

q_i = i to stanje prihvatanja.

(U slučaju $k = 0$, uzimamo da je r regularni izraz \emptyset .)

Primer



Direktnom analizom automata (M) dobijamo:

$r_{i,j}^{\{0\}}$	0	1	2	$r_{i,j}^{\{0,2\}}$	0	1	2
0				0	a^*	a^*b	
1	\emptyset	ϵ	a	1			
2	aa^*	a^*b	ϵ	2			

(nepopunjena polja matrica nam nisu potrebna)

Objašnjenje primera

Pošto počinjemo iz stanja 0, i ono je jedino stanje prihvatanja, jezik svih stringova koje automat prihvata određen je regularnim izrazom $r_{0,0}^{\{0,1,2\}}$. Ukoliko odlučimo da uklonimo stanje 1 iz skupa stanja, imamo

$$L(r_{0,0}^{\{0,1,2\}}) = L(r_{0,0}^{\{0,2\}} | r_{0,1}^{\{0,2\}} (r_{1,1}^{\{0,2\}})^* r_{1,0}^{\{0,2\}}). \quad (2)$$

Direktna analiza pokazuje da je $L(r_{0,0}^{\{0,2\}}) = L(a^*)$ i $L(r_{0,1}^{\{0,2\}}) = L(a^*b)$. Kako bismo izračunali $L(r_{1,1}^{\{0,2\}})$ kao i $L(r_{1,0}^{\{0,2\}})$, biramo da uklonimo stanje 2 iz razmatranja:

$$L(r_{1,1}^{\{0,2\}}) = L(r_{1,1}^{\{0\}} | r_{1,2}^{\{0\}} (r_{2,2}^{\{0\}})^* r_{2,1}^{\{0\}}) \quad (3)$$

$$L(r_{1,0}^{\{0,2\}}) = L(r_{1,0}^{\{0\}} | r_{1,2}^{\{0\}} (r_{2,2}^{\{0\}})^* r_{2,0}^{\{0\}}) \quad (4)$$

Objašnjenje primera, cont'd

Poslednja dva regularna izraza (navedena na prethodnom slajdu) mogu se odrediti sa slike. Stoga, $L(r_{1,1}^{\{0,2\}}) = L(\varepsilon|a(\varepsilon)^*(a^*b))$, što je isto što i $L(\varepsilon|aa^*b)$. Slično, $L(r_{1,0}^{\{0,2\}}) = L(\emptyset|a(\varepsilon)^*(aa^*))$, što je jednako sa $L(aa^*)$. Zamenom ovih vrednosti u jednačinu (1) dobijamo:

$$L(r_{0,0}^{\{0,1,2\}}) = L(a^* | a^*b (\varepsilon|aa^*b)^* aaa^*) \quad (5)$$

Dakle, $a^*|a^*b(\varepsilon|aa^*b)^*aaa^*$ je regularni izraz koji odgovara automatu iz primera. (Jasno je da bi se ovaj regularni izraz mogao dalje uprostiti, ali nećemo se sada time baviti.)

Dodatak: $Not(M)$

Za datu **DFA** M , $Not(M)$ je DFA sa svojstvima:

- $Stanja_{Not(M)} \stackrel{\text{def}}{=} Stanja_M$
- $\Sigma_{Not(M)} \stackrel{\text{def}}{=} \Sigma_M$
- prelazi u $Not(M)$ = prelazi u M
- početno stanje od $Not(M)$ = početno stanje od M
- $Prihvata_{Not(M)} = \{q \in Stanja_M \mid q \notin Prihvata_M\}$

Tada za svako $u \in L(Not(M))$ važi:

$$L(Not(M)) = \{u \in \Sigma^* \mid u \notin L(M)\}.$$

Dodatak: Ekvivalentni regularni izrazi

Definicija. Za dva regularna izraza r i s kažemo da su ekvivalentni ako $L(r) = L(s)$, tačnije, oni određuju tačno iste skupove stringova prepoznavanjem šablona (matching-om).

Dodatak: Ekvivalentni regularni izrazi, cont'd

Primetimo da su sledeći izrazi ekvivalentni:

$$L(r) \subseteq L(s) \wedge L(s) \subseteq L(r) \quad (6)$$

$$\iff (\Sigma^* \setminus L(r)) \cap L(s) = \emptyset = (\Sigma^* \setminus L(s)) \cap L(r) \quad (7)$$

$$\iff L((\sim r) \& s) = \emptyset = L((\sim s) \& r) \quad (8)$$

$$\iff L(M) = \emptyset = L(N) \quad (9)$$

gde su M i N DFA koji prihvataju skupove stringova koji se uparuju sa regularnim izrazima $(\sim r) \& s$ i $(\sim s) \& r$, respektivno.

Dakle, određivanje da li su dva regularna izraza ekvivalentna, svodi se na proveru da li ovako definisanu automati M i N prihvataju neki string. Ovu proveru ponovljamo konačan broj puta, jer automati imaju konačno mnogo stanja, i jer možemo ukloniti petlje sa dužih puteva.