

Automaten

Informatica, UvA

Yde Venema

Inhoud

Inleiding	1
1 Formele talen en reguliere expressies	2
1.1 Formele talen	2
1.2 Reguliere expressies	4
1.3 Equivalentie van reguliere expressies	6
2 Eindige automaten	8
2.1 Deterministische eindige automaten	8
2.2 Niet-deterministische eindige automaten	10
2.3 Determinizeren	12
3 De stelling van Kleene	17
3.1 Reguliere expressies uit eindige automaten	17
3.2 Eindige automaten uit reguliere expressies	23
4 Eigenschappen van reguliere talen	28
4.1 Pompstelling	28
4.2 Afsluitingseigenschappen	30
4.3 Algoritmische aspecten van reguliere talen	31
5 Automaten voor oneindige woorden	35
5.1 Büchi automaten en ω -reguliere talen	35
5.2 Reguliere ω -expressies	38
5.3 Muller automaten	39
5.4 Eigenschappen van ω -reguliere talen	43
6 Specificaties in Lineaire Temporele Logica	46
6.1 Lineaire Temporele Logica	46
6.2 Transitiesystemen	50
6.3 Lineaire temporele logica als specificatietaal	52
7 Model checking met behulp van eindige automaten	54
7.1 Muller automaten uit transitiesystemen	55
7.2 Muller automaten uit formules	57

1 Formele talen en reguliere expressies

1.1 Formele talen

Definitie 1.1 Een *alfabet* is een niet-lege, eindige verzameling van objecten die we *symbolen* of *letters* zullen noemen.

Voorbeeld 1.2 Voorbeelden van alfabetten zijn:

$$\begin{aligned}\Sigma_1 &:= \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}, \\ \Sigma_2 &:= \{a, b, c, \dots, x, y, z\}, \\ \Sigma_3 &:= \Sigma_1 \cup \Sigma_2 \cup \{+, -, *, =, :=\} \cup \{;, \text{if}, \text{then}, \text{else}, \text{fi}, \text{while}, \text{do}, \text{od}\}\end{aligned}$$

De Nederlandse taal bevat oneindig veel woorden, zodat de verzameling van alle Nederlandse woorden géén voorbeeld van een alfabet is.

Definitie 1.3 Een *woord* of *string* over een alfabet Σ is een eindig rijtje symbolen uit Σ . Het *lege woord* wordt weergegeven als ϵ . De verzameling van alle woorden over Σ wordt weergegeven als Σ^* .

Voorbeeld 1.4 De verzameling $\{a, b\}^*$ bestaat uit de woorden $\epsilon, a, b, aa, ab, ba, bb, aaa, \dots$

Definitie 1.5 Het samenvoegen van twee woorden door ze achter elkaar te zetten noemen we *concatenatie*; dezelfde term gebruiken we ook voor het product van deze operatie.

Voorbeeld 1.6 De concatenatie van de woorden ab en $bbac$ geeft (of *is*) het woord $abbbac$, concatenatie van de woorden ab , bc , ϵ en cd levert het woord $abbccd$ op.

Van belang zijn verder de volgende afgeleide begrippen.

Definitie 1.7 De *lengte* van een woord w , notatie: $|w|$, definiëren we als het aantal symbolen van w . De *frequentie* van een symbool in een woord is het aantal keren dat het symbool in het woord voorkomt.

Voorbeeld 1.8 Beschouw de statement “**if** $x = 3$ **then** $y := z$ ” als woord over het alfabet Σ_3 uit Voorbeeld 1.2. Er staan acht Σ_3 -symbolen in dit woord (merk op dat de spatie geen element van Σ_3 is!). Hiermee is de lengte vastgesteld: $|\text{if } x = 3 \text{ then } y := z| = 8$. De lengte van het lege woord is nul: $|\epsilon| = 0$.

Voorbeelden van frequenties: $\#_a(aabaaac) = 5$, $\#_b(aabaaac) = 1$ en $\#_d(aabaaac) = 0$.

Definitie 1.9 Een (*formele*) *taal* over een alfabet Σ is een verzameling woorden over Σ .

Dat wil zeggen: elke deelverzameling van Σ^* is een formele taal over Σ .

Voorbeeld 1.10 Stel eerst dat we als alfabet de verzameling $\Sigma = \{a, b\}$ nemen. Voorbeelden van formele talen zijn:

$$\begin{aligned} L_1 &= \{w \in \Sigma^* \mid |w| = 2\}, \\ L_2 &= \{w \in \Sigma^* \mid |w| > 2\}, \\ L_3 &= \{w \in \Sigma^* \mid \#_a w = k\}. \end{aligned}$$

Oftewel: $L_1 = \{aa, ab, ba, bb\}$, L_2 bestaat uit alle Σ -woorden die minstens drie symbolen bevatten, en L_3 bestaat uit die Σ -woorden waar precies k maal het symbool a in voorkomt.

Andere voorbeelden: de Nederlandse taal, opgevat als de verzameling (correct gespelde) Nederlandse woorden, kun je zien als een formele taal over het alfabet $\{a, b, \dots, z\}$. Programmeertalen zijn altijd formele talen over een alfabet vergelijkbaar met Σ_3 uit Voorbeeld 1.2.

Omdat formele talen gedefinieerd worden als *verzamelingen*, kun je er de gebruikelijke operaties op toepassen, zoals vereniging, doorsnede, en complement (dat wil zeggen, complement met betrekking tot de verzameling Σ^*). Daarnaast zijn er nog een aantal andere operaties op formele talen.

Definitie 1.11 Gegeven formele talen L over een alfabet Σ , definiëren we de volgende nieuwe formele talen:

$$\begin{aligned} L \circ L' &= \{ww' \mid w \in L, w' \in L'\} \\ L^0 &= \{\epsilon\} \\ L^{n+1} &= L \circ L^n \\ L^* &= \bigcup_{n \geq 0} L^n \end{aligned}$$

Voorbeeld 1.12 Beschouw het alfabet $\Sigma = \{a, b, c\}$, en definieer, voor elk natuurlijk getal k :

$$L_k := \{w \in \Sigma^* \mid \#_a w = k\}.$$

Dat wil zeggen: L_k bestaat uit die woorden over Σ waar precies k maal de letter a in voorkomt. Dan geldt bijvoorbeeld:

$$\begin{aligned} L_3 \circ L_5 &= L_8, \\ (L_2)^0 &= \{\epsilon\}, \\ (L_2)^n &= L_{2n}, \\ (L_2)^* &= \{w \in \Sigma^* \mid \#_a w \text{ is even}\}. \end{aligned}$$

1.2 Reguliere expressies

Definitie 1.13 Gegeven een alfabet Σ , definiëren we de collectie van *reguliere expressies over* Σ door middel van de volgende Backus-Naur vorm (BNF):

$$r ::= a \mid \epsilon \mid \emptyset \mid r + r \mid rr \mid r^*. \quad (1)$$

Hierbij staat a voor een willekeurig symbool uit Σ .

Voor wie niet bekend is met deze manier van definiëren: u dient (1) te zien als een verkorte notatie van de volgende inductieve definitie:

- alle symbolen $a \in \Sigma$, tesamen met ϵ en $\emptyset$, vormen de *atomaire* reguliere expressies;
- als r en s reguliere expressies zijn, dan ook $r + s$, rs en r^* .

Voorbeeld 1.14 Als voorbeelden van reguliere expressies over het alfabet $\Sigma = \{a, b\}$ noemen we: a^* , a^*b^* , ϵ , en $(a^*\emptyset + \epsilon b)^*$.

Reguliere expressies over een alfabet Σ kunnen worden gezien als *condities* waar een woord uit Σ^* al dan niet aan kan voldoen. In het geval een woord w voldoet aan de expressie r , spreken we van *matching*, notatie: $w \triangleright r$. Om precies te bepalen *wanneer* een woord matcht met een expressie, gebruiken we de volgende definitie.

Definitie 1.15 Gegeven is een alfabet Σ . Met inductie naar de complexiteit van de reguliere expressie r bepalen we of een woord w met deze expressie matcht:

$$\begin{aligned} w \triangleright a & \text{ als } w = a, \\ w \triangleright \epsilon & \text{ als } w = \epsilon, \\ w \triangleright \emptyset & \text{ nooit} \\ w \triangleright r + s & \text{ als } w \triangleright r \text{ of } w \triangleright s, \\ w \triangleright rs & \text{ als } w \text{ kan worden gesplitst als } w = uv \text{ zó dat } u \triangleright r \text{ en } v \triangleright s, \\ w \triangleright r^* & \text{ als } w = \epsilon \text{ of } w \triangleright r \text{ of } w \text{ kan worden gesplitst als } w = w_1 \dots w_k \\ & \text{zó dat } w_i \triangleright r \text{ voor elke } i. \end{aligned}$$

In woorden drukt de laatste clause uit dat een woord w matcht met een expressie van de vorm r^* als $w = \epsilon$ of w matcht met r , of w kan worden geschreven als de concatenatie van een aantal strings die allemaal met r matchen.

Voorbeeld 1.16 Laat $\Sigma = \{a, b, c\}$.

Dan geldt dat een Σ -woord w matcht met de expressie $(b + c)^*$ dan en slechts dan als er in w géén a 's voorkomen (ga na).

Verder geldt bijvoorbeeld dat het woord $w = bcaac$ matcht met de expressie $r = (b + c)^*a(b + c)^*a(b + c)^*$. We kunnen namelijk w opsplitsen in de woorden bc , a , ϵ , a en c , en voor deze woorden geldt:

- $bc \triangleright (b+c)^*$ omdat $b \triangleright b+c$ en $c \triangleright b+c$,
- $a \triangleright a$.
- $\epsilon \triangleright (b+c)^*$,
- $a \triangleright a$,
- $c \triangleright (b+c)^*$ omdat $c \triangleright b+c$.

In het algemeen geldt dat een woord w matcht met $r = (b+c)^*a(b+c)^*a(b+c)^*$ als w precies tweemaal het symbool a bevat, en dus geldt dat $w \triangleright r^*$ als w een *even* aantal a 's bevat.

De link tussen reguliere expressies en formele talen komt in de volgende definitie naar voren.

Definitie 1.17 Een reguliere expressie r *beschrijft* een taal $L(r)$, gegeven door de verzameling woorden die aan r voldoen. Preciezer:

$$L(r) := \{w \in \Sigma^* \mid w \triangleright r\}.$$

Voorbeeld 1.18 Hier zijn een aantal eenvoudige voorbeelden van talen over $\{a, b, c\}^*$:

$$\begin{aligned} L(a+b+\epsilon) &= \{a, b, \epsilon\}, \\ L(a+b+\emptyset) &= \{a, b\}, \\ L(a+b^*) &= \{a, \epsilon, b, bb, bbb, \dots\}, \\ L((a+b)^*) &= \{\epsilon, a, b, aa, ab, ba, bb, aaa, \dots\}, \\ L(a(a+b+c)^*) &= \{w \in \{a, b, c\}^* \mid w \text{ begint met een } a\}, \end{aligned}$$

Aan het einde van Voorbeeld 1.16 zagen we al dat

$$L\left(((b+c)^*a(b+c)^*a(b+c)^*)^*\right) = \{w \in \{a, b, c\}^* \mid \#_a w \text{ is even}\}.$$

Als laatste nog een wat moeilijker voorbeeld: de taal bestaande uit alle woorden in $\{a, b, c\}^*$ die *niet* met de string ab beginnen, wordt beschreven door de expressie $\epsilon + a + (b+c)(a+b+c)^* + a(a+c)(a+b+c)^*$.

Voorbeeld 1.19 Als een uitgewerkt voorbeeld laten we zien, voor het geval dat $\Sigma = \{a, b\}$, dat

$$L(b^*(a(\epsilon + bbb^*))^*(\epsilon + b)) = \{w \in \Sigma^* \mid w \text{ bevat } aba \text{ niet als deelstring}\}.$$

We behandelen eerst de inclusie $\subseteq$. Stel dus dat $w \in \{a, b\}^*$ matcht met de expressie $b^*(a(\epsilon + bbb^*))^*(\epsilon + b)$. Dan is w dus van de vorm $w = w_1 w_2 w_3$, zó dat

- $w_1 \triangleright b^*$, dus w_1 bevat geen a 's;
- $w_2 \triangleright (a(\epsilon + bbb^*))^*$, dus w_2 kan gesplitst worden in een aantal woorden die elk matchen met de expressie $a(\epsilon + bbb^*)$;

- $w_3 \triangleright (\epsilon + b)$, dus w_3 bevat ook geen a 's.

Kan w het woord aba als deelstring bevatten? De enige mogelijkheid is dat aba in zijn geheel een deelstring van w_2 vormt, dus laten we nog wat beter kijken naar w_2 . Wegens de bovenstaande analyse moet w_2 , als het überhaupt meer dan één a bevat, van de vorm

$$\underbrace{ab \dots b} \dots \underbrace{ab \dots b}$$

zijn, waarbij het aantal b 's tussen opéénvolgende a 's steeds óf nul (ϵ), óf minimaal twee (bbb^*) moet zijn. Het kan dus niet voorkomen, dat twee a 's worden gescheiden door precies één b . Maar dan kan w_2 het woord aba niet als deelstring bevatten, en w zelf dus ook niet. Dit bewijst de inclusie $\subseteq$.

Voor de andere inclusie nemen we aan dat de string aba niet voorkomt in w . Dat betekent dat er tussen elke twee opéénvolgende a 's in w , ofwel géén, ofwel minimaal twee b 's voorkomen. Het woord w moet dan wel van de volgende vorm zijn:

- eerst een aantal (nul of meer) b 's;
- dan een aantal keren (afhankelijk van de frequentie van a in w) een woord van de vorm ab^n , waarbij $n = 0$ of $n \geq 2$;
- het woord kan eventueel worden afgesloten door één enkele b .

Met andere woorden, w kan worden gesplitst in drie woorden die respectievelijk moeten matchen met de expressies b^* , $(a(\epsilon + bbb^*))^*$ en $\epsilon + b$. Hieruit volgt onmiddellijk dat w moet matchen met de expressie $b^*(a(\epsilon + bbb^*))^*(\epsilon + b)$.

De volgende propositie maakt het verband met de operaties van Definitie 1.11 duidelijk.

Propositie 1.20 Gegeven is een alfabet Σ . Er geldt, voor elk symbool $a \in \Sigma$, en voor alle reguliere expressies r en s over Σ :

$$\begin{aligned} L(\emptyset) &= \emptyset \\ L(\epsilon) &= \{\epsilon\} \\ L(a) &= \{a\} \\ L(r + s) &= L(r) \cup L(s) \\ L(rs) &= L(r) \circ L(s) \\ L(r^*) &= (L(r))^* \end{aligned}$$

1.3 Equivalentie van reguliere expressies

Voorbeeld 1.21 De expressies $bc(bc)^*$ en $(bc)^*bc$ beschrijven precies dezelfde taal, namelijk die bestaande uit de woorden $bc, bcbc, bcbcbc, \dots$. Meer in het algemeen kun je laten zien dat voor elke expressie r geldt dat $L(rr^*) = L(r^*r)$. De expressies rr^* en r^*r heten daarom *equivalent*.

Definitie 1.22 Twee reguliere expressies heten *equivalent* als ze één en dezelfde taal beschrijven.

Voorbeeld 1.23 Eerst een tegenvoorbeeld. Omdat de string $aabb$ wel matcht met de expressie a^*b^* , maar niet met b^*a^* , zijn de expressies a^*b^* en b^*a^* niet equivalent.

Voorbeelden van expressies die wel equivalent zijn (wat we ook nemen voor r , s of t):

- $r + s$ en $s + r$,
- $r(s + t)$ en $rs + rt$,
- r^* en $\epsilon + rr^*$.

We bewijzen alleen het tweede voorbeeld. Dat wil zeggen: we beredeneren dat

$$L(r(s + t)) = L(rs + rt). \quad (2)$$

Stel eerst dat w een element is van $L(r(s + t))$; dat betekent dat w matcht met $r(s + t)$. Per definitie kan w dus worden gesplitst als $w = uv$ zó dat $u \triangleright r$ en $v \triangleright s + t$. Uit het laatste feit volgt dat $v \triangleright s$ of $v \triangleright t$. In het eerste geval mogen we concluderen dat $w \triangleright rs$, in het tweede geval dat $w \triangleright rt$; in beide gevallen volgt dat $w \triangleright rs + rt$, zodat we bewezen hebben dat w een element is van $L(rs + rt)$.

De andere richting (aannemende dat $w \in L(rs + rt)$, laten zien dat w tot $L(r(s + t))$ behoort), laten we over aan de lezer.

Opgaven

Opgave 1.1 Onderzoek of de volgende woorden matchen met de expressie $(ab + aa + baa)^*$.

$bbaba$, $abaabaaabaa$, $aaaabaaaa$, $baaaaabaa$, $baaaaabaaaab$.

Opgave 1.2 In UNIX kun je met het commando `ls` alle files in een directory bekijken. Maar het is ook mogelijk alleen maar bepaalde files te laten zien. Hierbij kun je gebruik van de volgende expressies maken:

- $?$ $\sim$ een willekeurig element uit Σ ,
- $*$ $\sim$ een willekeurig element uit Σ^* ,
- $[n_1..n_2]$ $\sim$ een cijfer tussen n_1 en n_2 (n_1 en n_2 zelf meegerekend),
- $[l_1..l_2]$ $\sim$ (een letter tussen l_1 en l_2 (l_1 en l_2 zelf meegerekend)).

Het alfabet Σ is daarbij als volgt gedefinieerd:

$$\Sigma := \{a, b, \dots, z\} \cup \{A, B, \dots, Z\} \cup \{0, \dots, 9\} \cup \{., -\}$$

Schrijf de volgende UNIX-expressies als reguliere expressies:

- (a) $[2..6]?$
- (b) $*$

(c) $*[k..z]$

Opgave 1.3 Geef reguliere expressies voor de volgende talen in $\{a, b\}$:

- (a) $\{w \mid |w| = 2\}$
- (b) $\{w \mid |w| > 2\}$
- (c) $\{awa \mid w \in \{a, b\}^*\}$
- (d) $\{w \mid w \neq aba, w \neq bab\}$
- (e) $\{w \mid \#_a(w) \text{ is een drievoud}\}$
- (f) $\{w \mid \#_a(w) \text{ is geen drievoud}\}$
- (g) $\{w \mid w \text{ eindigt niet op } ab\}$
- (h) $\{w \mid w \text{ heeft } aba \text{ niet als deelstring}\}$

Opgave 1.4 Welke talen worden door de volgende expressies weergegeven?

- (a) $(1 + \epsilon)(00^*1)^*0^*$
- (b) $(0^*1^*)^*000(0 + 1)^*$
- (c) $(0 + 10)^*1^*$

Opgave 1.5 Gegeven is het alfabet $\Sigma = \{0, 1\}$. Welke talen worden weergegeven door de volgende expressies?

$0, \emptyset, \epsilon, 0^*, \emptyset^*, \epsilon^*, (0\emptyset)^*$.

Opgave 1.6 Gegeven is een alfabet Σ , en reguliere expressies r en s over Σ . Ga na of de volgende reguliere expressies paarsgewijs equivalent zijn. Verklaar uw antwoord!

- (a) rr^* en r^*r
- (b) $(r + s)^*$ en $r^* + s^*$
- (c) $(r + s)^*$ en $(r^*s^*)^*$
- (d) $(r + s)^*$ en $(rs^*)^*$
- (e) de UNIX-expressies $[a..c + b..f]^*$ en $[a..f]^*$
- (f) de UNIX-expressies $*$ en * ?

Opgave 1.7 Gegeven is een eindige verzameling woorden E . Ontwerp een efficiënte algoritme om te bepalen of een invoerwoord al dan niet tot E^* behoort. (Met efficiënt wordt hier bedoeld dat de algoritme een rekentijd heeft die polynomiaal is in de lengte van de invoer.)