

Informatik Q3 Abels



Reguläre Ausdrücke

Reguläre Ausdrücke

Definition

Mit einem regulären Ausdruck wird
(alternativ zur Tabelle oder zum
Graphen) eine formale Sprache
definiert.

Reguläre Ausdrücke

Beispiel: " $\Sigma = \{0, 1\}$ "

Regulärer Ausdruck	Wortmenge / Formale Sprache	Beschreibung: "Die Sprache, die ..."
\emptyset	$\{\}$... nichts enthält (leere Menge).
ϵ	$\{\epsilon\}$... nur das leere Wort enthält.
0	$\{0\}$... nur eine 0 enthält.
1	$\{1\}$... nur eine 1 enthält.
10	$\{10\}$... nur das Wort "10" enthält.
1 0	$\{1,0\}$... nur aus einer 0 und einer 1 besteht.
1^*	$\{\epsilon, 1, 11, 111, 1111, \dots\}$... aus allen Wörtern mit beliebig vielen (auch gar keine) 1en besteht.
01^*	$\{0, 01, 011, 0111, 01111, \dots\}$... aus allen Wörtern besteht, bei denen auf eine 0 beliebig viele (auch gar keine) 1en folgen.
0^*1^*	$\{\epsilon, 0, 00, \dots, 1, 01, 001, \dots, 11, 011, 0011, \dots\}$... aus allen Wörtern besteht, bei denen auf beliebig viele (auch gar keine) 0en beliebig viele (auch gar keine) 1en folgen.
$0^* 1^*$	$\{\epsilon, 0, 00, 000, \dots, 1, 11, 111, \dots\}$... aus allen Wörtern mit entweder beliebig vielen (auch gar keinen) 0en oder beliebig vielen (auch gar keinen) 1en besteht.
$0 (1(0 1)^*)$	$\{0, 1, 10, 11, 100, 101, 110, 111, \dots\}$... die Binärzahlen darstellt.
1^+	$\{1, 11, 111, 1111, \dots\}$... aus Wörtern nur aus 1en mit mindestens einer 1 besteht. (nicht verwechseln mit 1^*)
$1?$	$\{\epsilon, 1\}$... nur aus 1 oder dem leeren Wort besteht. Das ? bedeutet, dass das Zeichen davor optional vorkommen kann.

Reguläre Ausdrücke

Regeln

- \emptyset ist ein regulärer Ausdruck. Er beschreibt die leere Wortmenge $\{\}$.
- ϵ ist ein regulärer Ausdruck. Er beschreibt die Wortmenge $\{\epsilon\}$, in der nur das leere Wort vorkommt.
- Für jedes $a \in \Sigma$ ist a ein regulärer Ausdruck. Der reguläre Ausdruck a beschreibt die Wortmenge $\{a\}$.
- Wenn α und β reguläre Ausdrücke sind, dann ist auch die **Konkatenation** $\alpha\beta$ ein regulärer Ausdruck. Wenn α die Wortmenge A und β die Wortmenge B beschreibt, dann beschreibt die Konkatenation $\alpha\beta$ die Menge $\{ab \mid a \in A \text{ und } b \in B\}$ aller Wörter, die mit einem Wort aus A beginnen und mit einem Wort aus B enden.
- Wenn α und β reguläre Ausdrücke sind, dann ist auch die **Alternative** $\alpha|\beta$ ein regulärer Ausdruck. Wenn α die Wortmenge A und β die Wortmenge B beschreibt, dann beschreibt die Alternative $\alpha|\beta$ die Menge $\{\omega \mid \omega \in A \text{ oder } \omega \in B\}$ aller Wörter, die in A oder in B vorkommen.
- Wenn α ein regulärer Ausdruck ist, dann ist auch die **Iteration** α^* ein regulärer Ausdruck. Wenn α die Wortmenge A beschreibt, dann beschreibt die Iteration α^* die Menge A^* aller Wörter, die durch endlich häufiges Aneinanderfügen (auch keinmal) von Wörtern aus A entstehen.



Übung 1

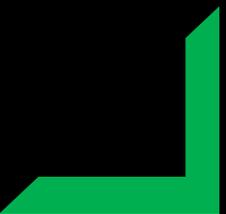
Erkläre jeweils, welche Wortmenge beschrieben wird:

a) $R_1 = (\textit{halli})^* \textit{hallo}$

b) $R_2 = \textit{Too}^* r$

c) $R_3 = (5|6|7|8|9|10)(a|b|c|d)$

d) $R_4 = ((0|1)(0|1|2|3|4|5|6|7|8|9))|(2(0|1|2|3)): (0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9)$





Übung 1



a) $R_1 = (\textit{halli})^* \textit{hallo}$

$$L_1 = \{\textit{hallo}, \textit{hallihallo}, \textit{hallihallihallo}, \textit{hallihallihallihallo}, \dots\}$$

b) $R_2 = \textit{Too}^* \textit{r}$

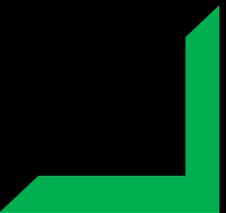
$$L_2 = \{\textit{Tor}, \textit{Toor}, \textit{Tooor}, \textit{Toooooor}, \textit{Tooooooor}, \textit{Toooooooor}, \dots\}$$

c) $R_3 = (5|6|7|8|9|10)(a|b|c|d)$

$$L_3 = \{5a, 5b, 5c, 5d, 6a, 6b, 6c, 6d, 7a, 7b, 7c, 7d, 8a, 8b, 8c, 8d, 9a, \dots, 10d\}$$

d) $R_4 = ((0|1)(0|1|2|3|4|5|6|7|8|9))|(2(0|1|2|3)): (0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9)$

$$L_4 = \{00:00, \dots, 16:23, \dots, 21:45, \dots, 23:59\}$$



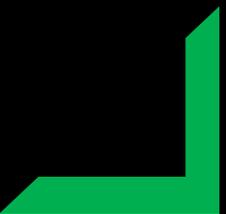


Übung 2

Gib einen regulären Ausdruck zur Beschreibung der Menge aller vereinfachten E-Mail-Adressen, die nach den folgenden Regeln gebildet werden, an:

Eine vereinfachte E-Mail-Adresse besteht aus einem User-Namen gefolgt vom @-Symbol und einer Domain-Angabe. Der User-Name soll nur aus b^* s bestehen. Die Domainangabe soll aus Subdomains mit einer Topleveldomain aufgebaut sein, die jeweils mit einem Punkt getrennt werden. Während die Subdomains aus beliebig vielen b^* s bestehen, soll die Topleveldomain aus genau zwei b^* s bestehen.

Beispiel: `bb@b.bbb.bb`



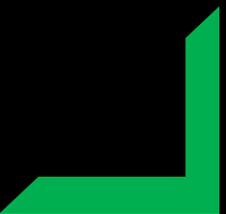


Übung 2

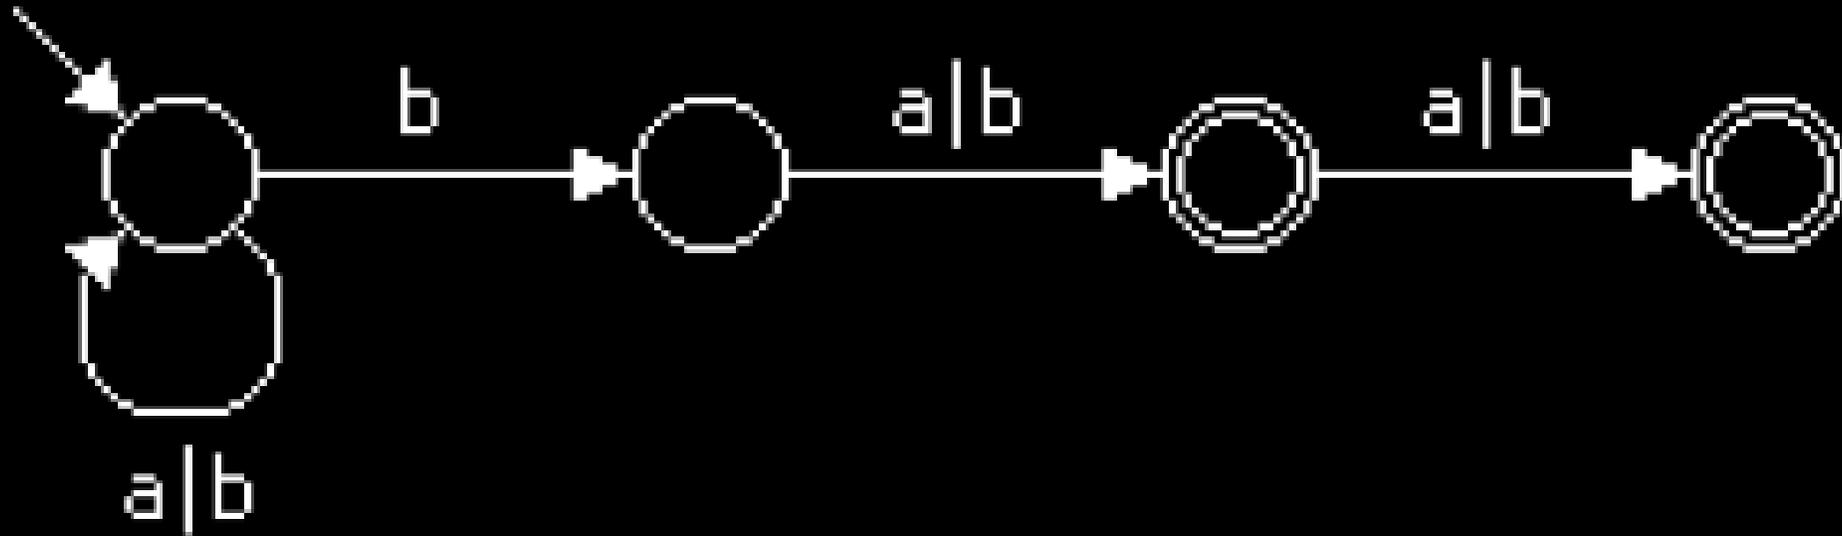


$R = b + @(b+.)^*.bb$

https://www.w3schools.com/tags/att_input_pattern.asp

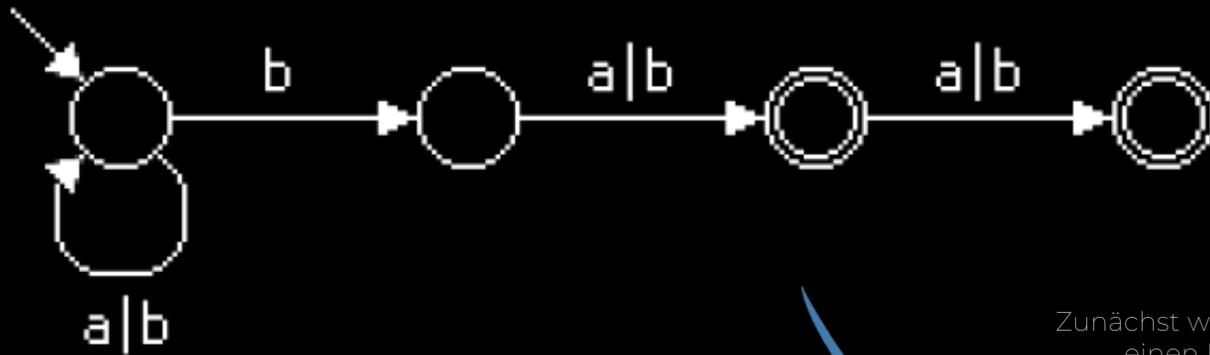


Akzeptor \rightarrow Regulärer Ausdruck

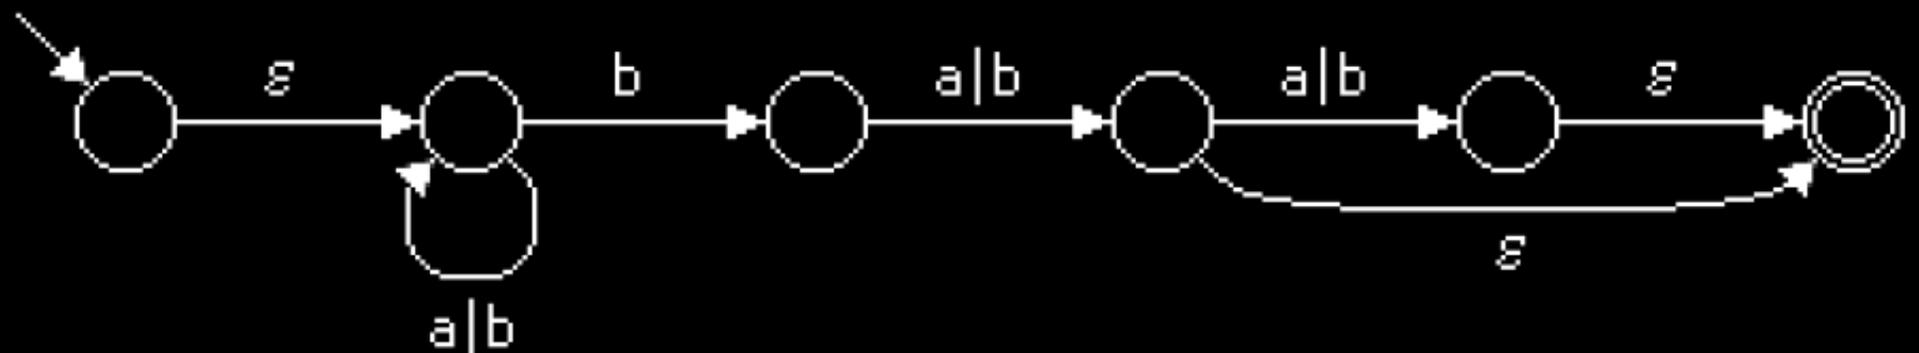


Akzeptor \rightarrow Regulärer Ausdruck

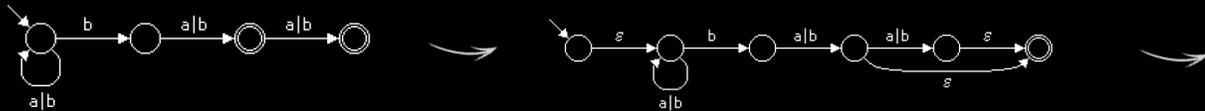
1



Zunächst wird ein neuer Startzustand eingeführt und durch einen Epsilon-Übergang mit dem ursprünglichen Startzustand verbunden. Ferner wird ein neuer Endzustand eingeführt. Alle bisherigen Endzustände verlieren ihre Endzustandseigenschaft; sie werden mit dem neuen Endzustand durch Epsilon-Übergänge verbunden.

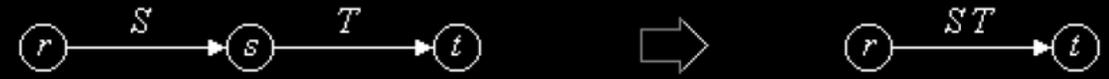


Akzeptor \rightarrow Regulärer Ausdruck



Außer dem Startzustand und dem Endzustand werden nun schrittweise alle Zustände nach folgenden Regeln entfernt. Wenn ein Zustand s entfernt wird, so wird jeder Kantenzug $(r, s)(s, t)$ mit r, t durch eine Kante (r, t) ersetzt. Sind hierbei die Kanten (r, s) und (s, t) mit den regulären Ausdrücken S bzw. T beschriftet, so wird die neue Kante (r, t) ...

a) ... mit dem regulären Ausdruck ST beschriftet, wenn keine Kante (s, s) vorhanden ist.

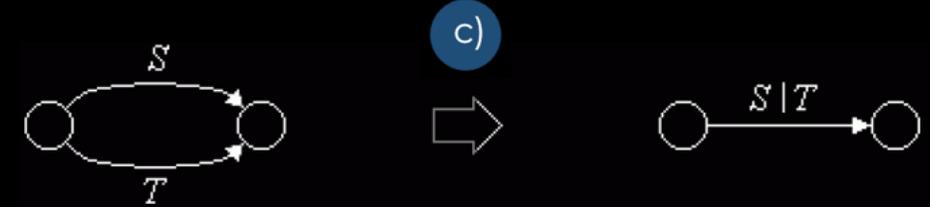


b) ... mit dem regulären Ausdruck SX^*T beschriftet, wenn eine Kante (s, s) vorhanden ist, die mit dem regulären Ausdruck X beschriftet ist.



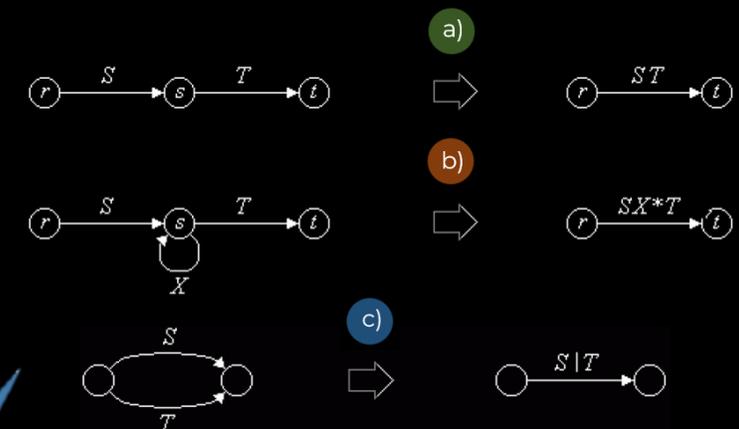
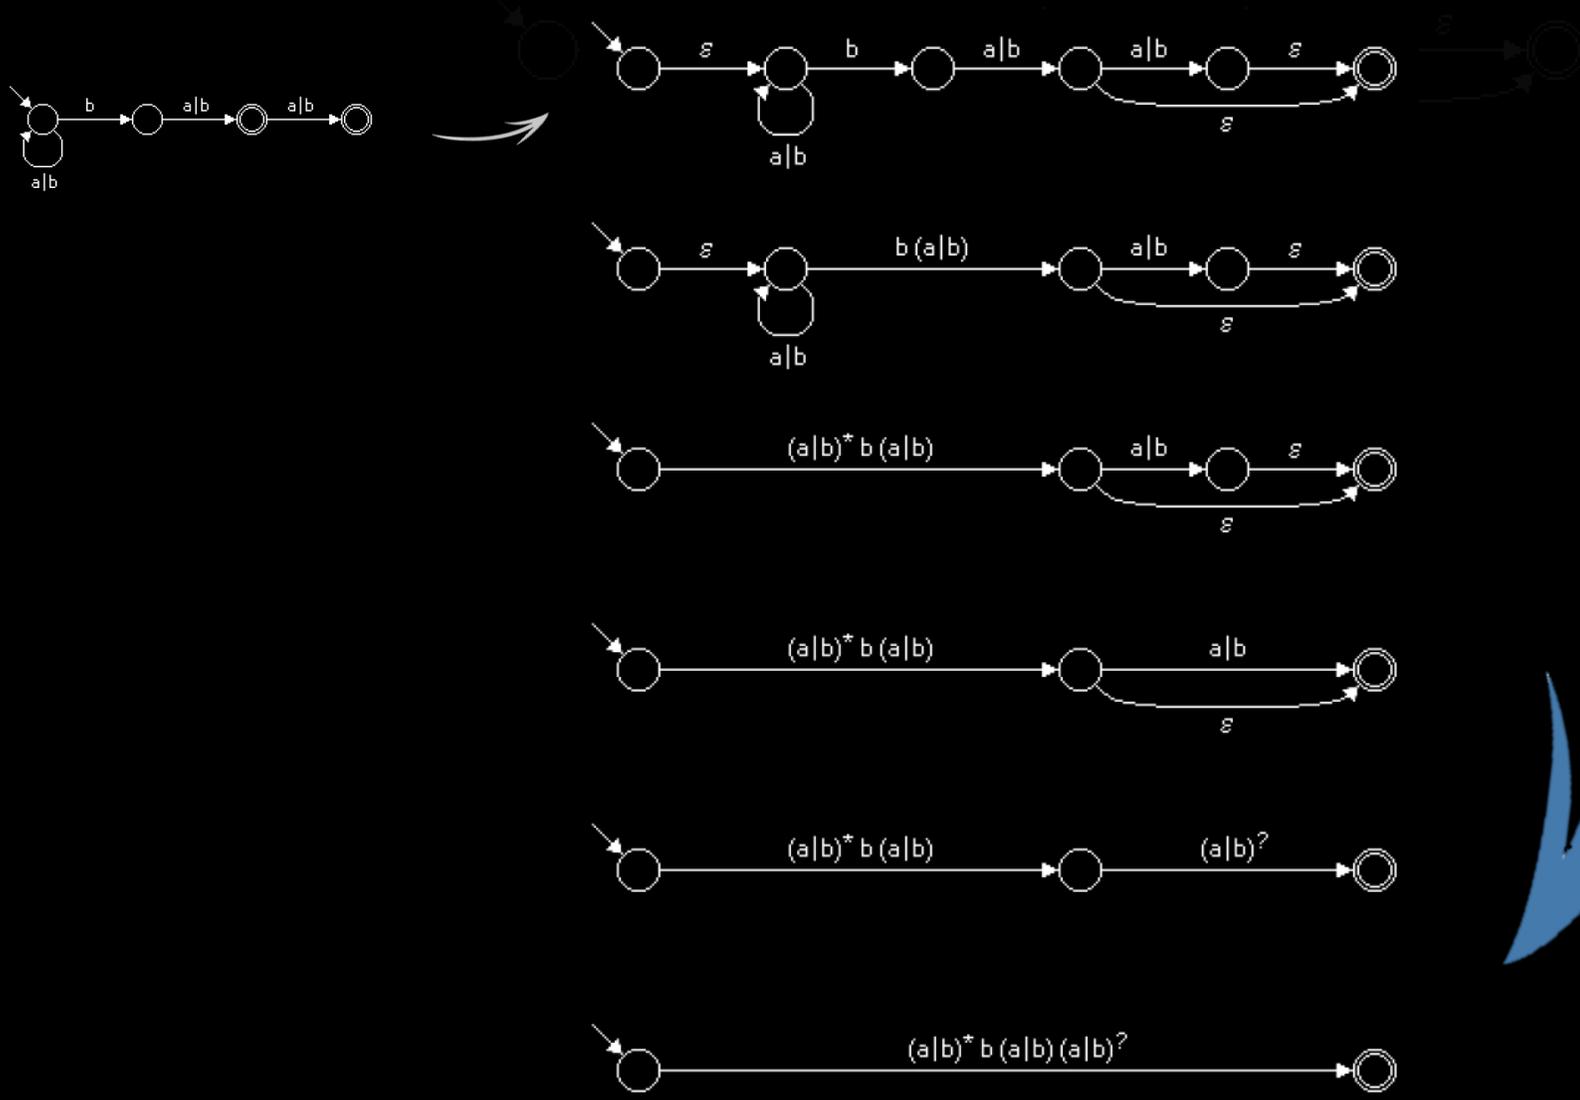
c)

Ist nach dem Entfernen eines Zustands eine Doppelkante zwischen zwei Zuständen vorhanden, so wird diese durch eine einfache Kante ersetzt. Die Beschriftung dieser neuen Kante ist $S|T$, wenn S bzw. T die Beschriftungen der Doppelkante waren.

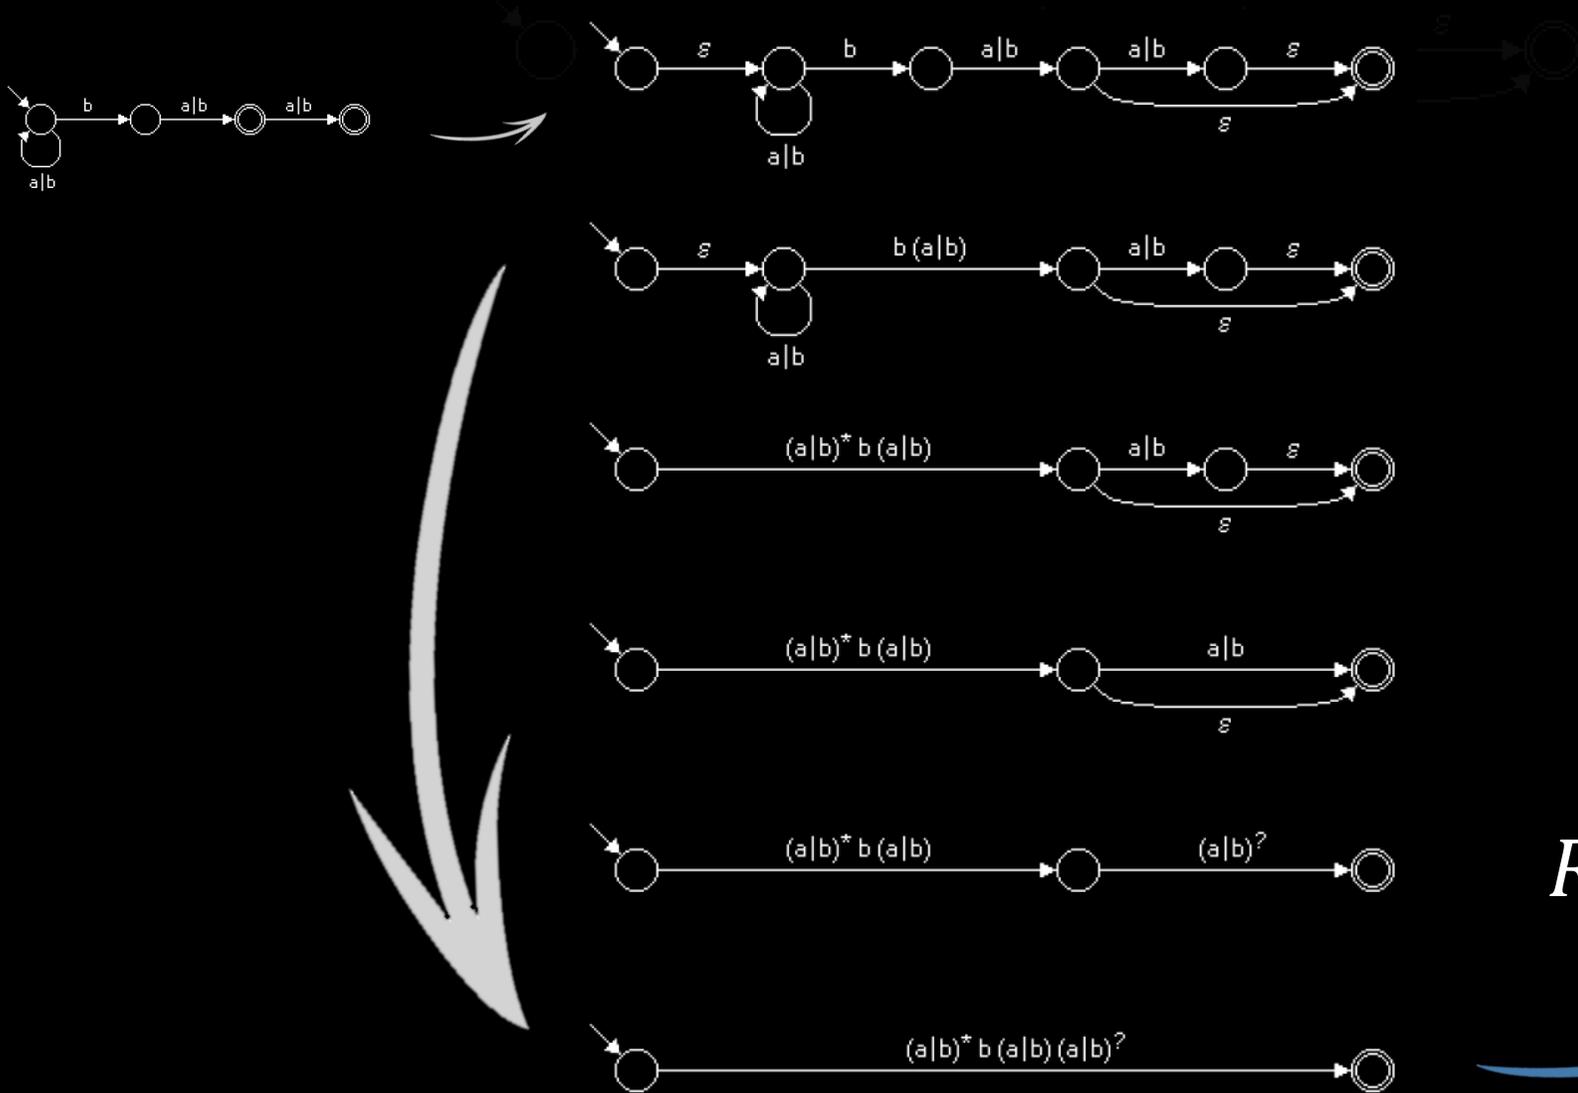


Akzeptor \rightarrow Regulärer Ausdruck

2



Akzeptor \rightarrow Regulärer Ausdruck

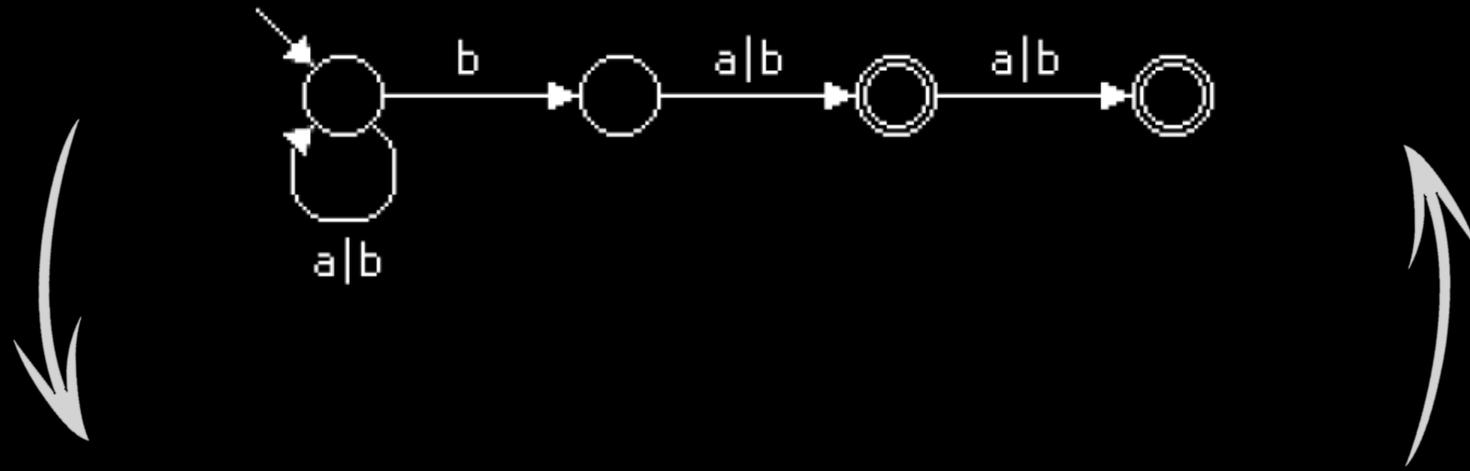


3

$$R = (a|b)^* b (a|b) (a|b)?$$



Akzeptor \rightarrow Regulärer Ausdruck



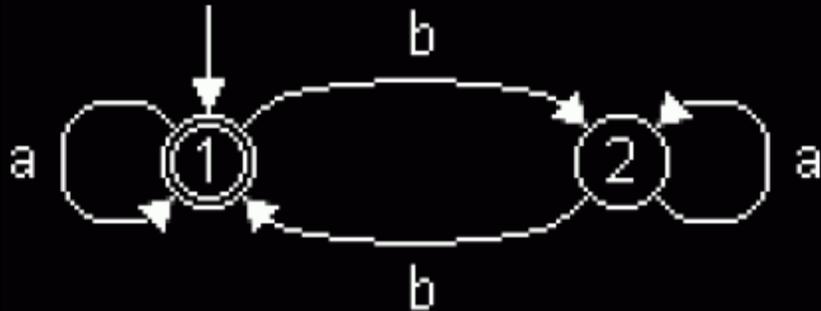
$$R = (a|b)^*b(a|b)(a|b)?$$



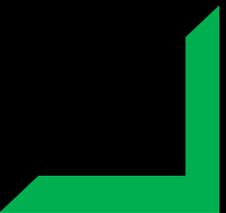
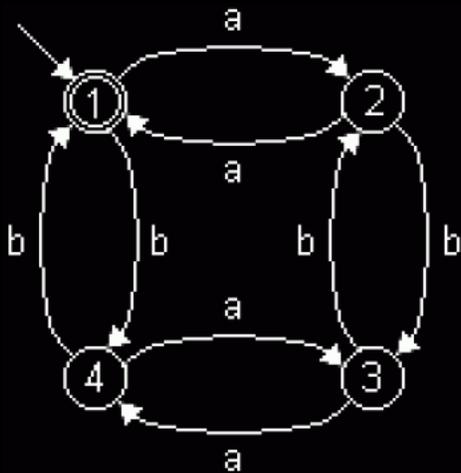
Übung 3

Erzeuge zu den gegebenen DEA's jeweils den zugehörigen regulären Ausdruck:

a)

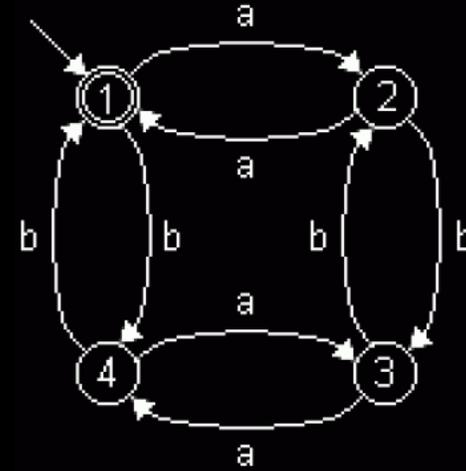
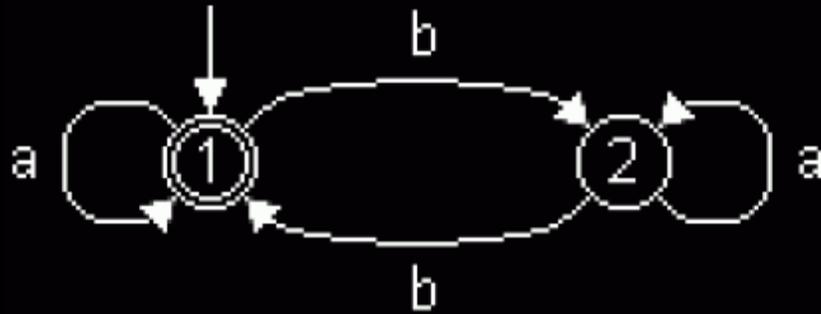


b)

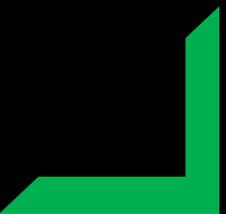




Übung 3



$$R_a = (a|ba^*b)^*$$



Regulärer Ausdruck \rightarrow Akzeptor

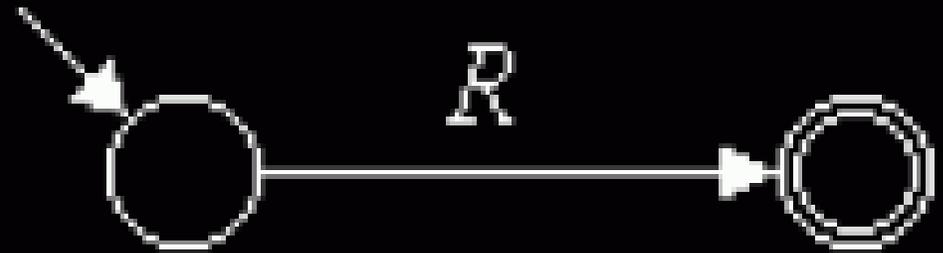
$$R = a(a|b)^*a|a$$

Regulärer Ausdruck \rightarrow Akzeptor

1

$$R = a(a|b)^*a|a$$

Als erstes wird ein Zustandsgraph mit einem Startzustand und einem Endzustand erzeugt. Startzustand und Endzustand sind durch einen Zustandsübergang miteinander verbunden, der mit dem regulären Ausdruck R beschriftet ist (Bild 1). Dieser Zustandsgraph beschreibt offenbar das Verhalten eines Automaten, der die reguläre Sprache $L(R)$ erkennt – allerdings nur ganz grob, die inneren Zustände des Automaten bleiben zunächst unbestimmt.



Regulärer Ausdruck \rightarrow Akzeptor

$R = a(a|b)^*a|a$ \rightarrow  \rightarrow ...

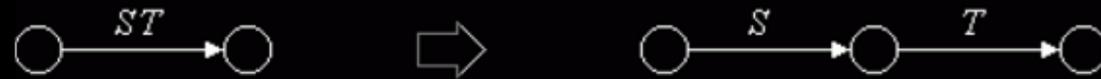
2

Durch Zerlegung dieses Zustandsübergangs werden nach und nach die inneren Zustände des Automaten erzeugt. Dabei gelten folgende Regeln:

a) Jeder Zustandsübergang, der mit $S|T$ beschriftet ist, wird in zwei parallele Zustandsübergänge zerlegt, die mit S bzw. mit T beschriftet sind.



b) Jeder Zustandsübergang, der mit ST beschriftet ist, wird in zwei aufeinander folgende Zustandsübergänge zerlegt, die mit S bzw. mit T beschriftet sind.

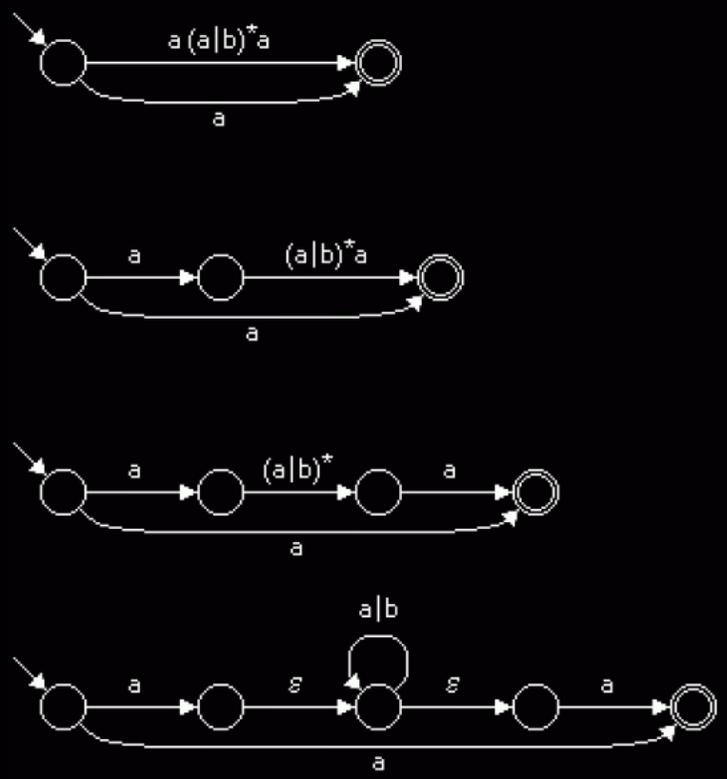
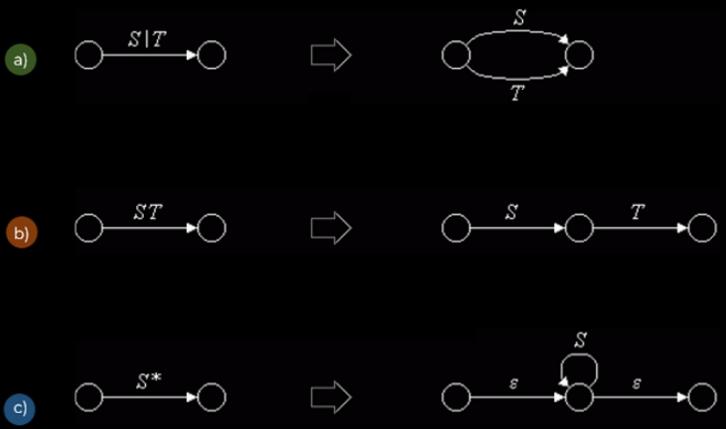


c) Jeder Zustandsübergang, der mit S^* beschriftet ist, wird zerlegt.



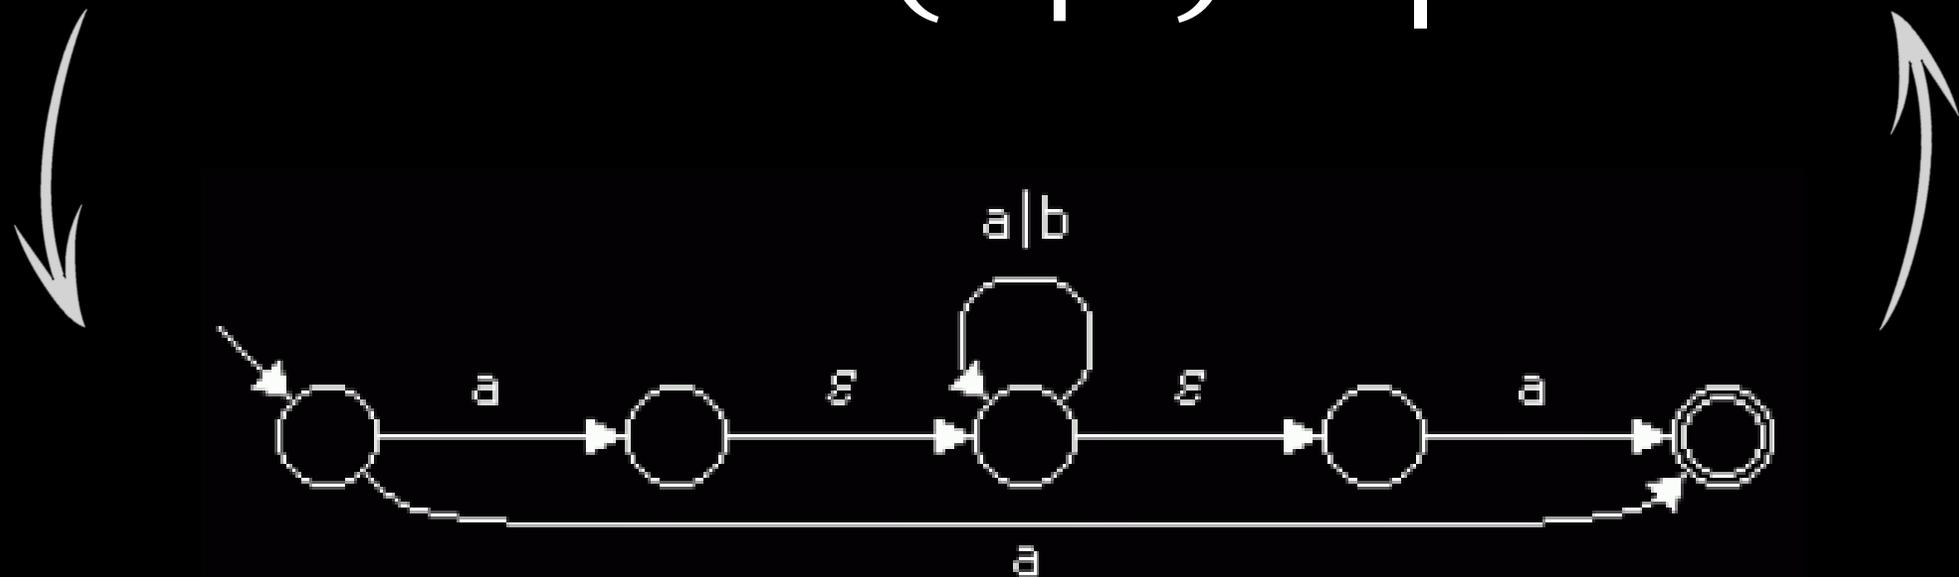
Regulärer Ausdruck \rightarrow Akzeptor

2



Regulärer Ausdruck \rightarrow Akzeptor

$$R = a(a|b)^*a|a$$

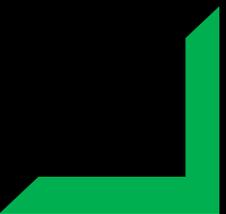




Übung 4

Erstelle zu den folgenden regulären Ausdrücken jeweils das zum Automaten gehörige Zustandsdiagramm:

- a) ab
- b) $a(b|c)$
- c) 10^*1
- d) $0|1(0|1)^*$

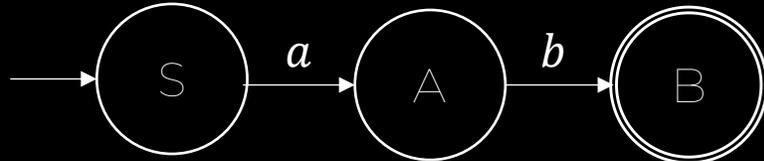




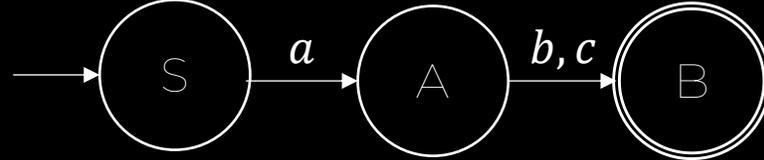
Übung 4



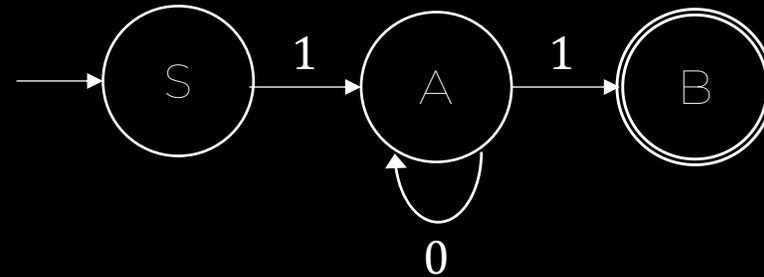
a) ab



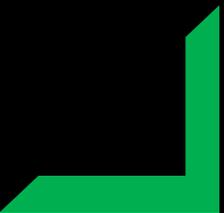
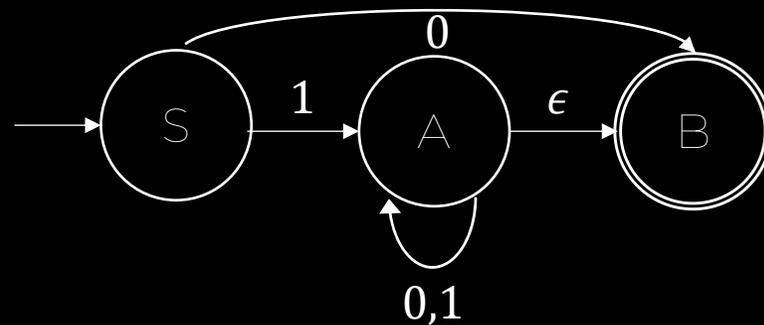
b) $a(b|c)$



c) 10^*1



d) $0|1(0|1)^*$



Satz

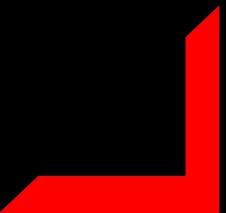
reguläre Sprache

Die Klasse der Sprachen, die mit einer **regulären Grammatik** beschrieben werden können, ist identisch mit der Klasse der Sprachen, die mit einem **regulären Ausdruck** beschrieben werden können. Sie ist ebenso identisch mit der Klasse der Sprachen, die von **deterministischen endlichen Automaten** bzw. von **nichtdeterministischen endlichen Automaten** erkannt werden können.



Tagebucheintrag

Reguläre Ausdrücke





Wochenübung

Konstruiere einen NEA aus folgendem regulären Ausdruck ...

$$R = (a|ba|bba)^*(\epsilon|b|bb)$$

... über dem Alphabet $\Sigma = \{a, b\}$.

Die erzeugte Sprache umfasst alle Wörter über Σ , die höchstens zwei ***b***'s hintereinander enthalten.

