

Reguläre Ausdrücke

Prof. Dr. Jasmin Blanchette

Lehr- und Forschungseinheit für
Theoretische Informatik

Stand: 9. Mai 2023

Folien ursprünglich von PD Dr. David Sabel



(Wiederholung für FSK:) NFAs mit ε -Übergängen

- ▶ ε -Übergänge erlauben Zustandswechsel **ohne** Lesen eines Zeichens (es wird sozusagen das leere Wort ε gelesen).
- ▶ Ausdruckskraft ändert sich mit ε -Übergängen nicht.
- ▶ ε -Übergänge machen manche Konstruktionen einfacher.


Definition (NFA mit ε -Übergängen)

Ein **nichtdeterministischer endlicher Automat mit ε -Übergängen**

(NFA mit ε -Übergängen) ist ein 5-Tupel $M = (Z, \Sigma, \delta, S, E)$ wobei


- ▶ Z ist eine endliche Menge von Zuständen,
- ▶ Σ ist das (endliche) Eingabealphabet mit $Z \cap \Sigma = \emptyset$,
- ▶ $\delta : Z \times (\Sigma \cup \{\varepsilon\}) \rightarrow \mathcal{P}(Z)$ ist die Zustandsüberföhrungsfunktion,
- ▶ $S \subseteq Z$ ist die Menge der Startzustände und
- ▶ $E \subseteq Z$ ist die Menge der Endzustände.

(Wiederholung für FSK:) Beispiel: NFA mit ϵ -Übergängen



Akzeptierte Sprache: ?

(Wiederholung für FSK:) Beispiel: NFA mit ϵ -Übergängen



Akzeptierte Sprache:

alle Wörter aus $\{a, b, c\}^*$, die an letzter, vorletzter oder drittletzter Position ein a haben, und das leere Wort

Eindeutige Start- und Endzustände

Satz 4.6.8


Für jeden NFA M mit ε -Übergängen gibt es einen NFA M' mit ε -Übergängen, sodass $L(M) = L(M')$ und M' genau einen Startzustand und genau einen Endzustand hat, wobei diese beiden Zustände verschieden sind.

Eindeutige Start- und Endzustände


Satz 4.6.8

Für jeden NFA M mit ε -Übergängen gibt es einen NFA M' mit ε -Übergängen, sodass $L(M) = L(M')$ und M' genau einen Startzustand und genau einen Endzustand hat, wobei diese beiden Zustände verschieden sind.


Beweis: Konstruiere M' aus M , durch Hinzufügen eines neuen Start- und eines neuen Endzustand mit ε -Übergängen:



Beispiel



wird zu



Reguläre Ausdrücke

- ▶ Reguläre Ausdrücke sind (wie Automaten und Grammatiken) ein Formalismus zur Repräsentation von Sprachen.
- ▶ Praktische Verwendung: Regex-Bibliotheken in Programmiersprachen oder bei der Shell-Programmierung zum Suchen und Ersetzen von Zeichenketten (verwenden meist **erweiterte** reguläre Ausdrücke)
- ▶ Aufbau regulärer Ausdrücke:
Basisausdrücke und Operatoren zum Zusammensetzen

Definition (Regulärer Ausdruck)

Sei Σ ein Alphabet. Die **regulären Ausdrücke** über Σ sind induktiv definiert:

- ▶ \emptyset ist ein regulärer Ausdruck
- ▶ ε ist ein regulärer Ausdruck
- ▶ a mit $a \in \Sigma$ ist ein regulärer Ausdruck
- ▶ Wenn α_1 und α_2 reguläre Ausdrücke sind, dann auch $\alpha_1\alpha_2$
- ▶ Wenn α_1 und α_2 reguläre Ausdrücke sind, dann auch $(\alpha_1|\alpha_2)$
- ▶ Wenn α ein regulärer Ausdruck ist, dann auch $(\alpha)^*$

Reguläre Ausdrücke (3)

Erzeugte Sprache

Die von einem regulären Ausdruck α erzeugte Sprache $L(\alpha)$ ist rekursiv definiert:

$$L(\emptyset) := \emptyset$$

$$L(\varepsilon) := \{\varepsilon\}$$

$$L(a) := \{a\} \text{ für } a \in \Sigma$$

$$L(\alpha_1\alpha_2) := L(\alpha_1)L(\alpha_2) = \{uv \mid u \in L(\alpha_1), v \in L(\alpha_2)\}$$

$$L(\alpha_1|\alpha_2) := L(\alpha_1) \cup L(\alpha_2)$$

$$L((\alpha)^*) := L(\alpha)^*$$

Für alle regulären Ausdrücke $\alpha_1, \alpha_2, \alpha_3$ gilt:

$$L((\alpha_1|\alpha_2)|\alpha_3) = L(\alpha_1|(\alpha_2|\alpha_3))$$

Daher lassen wir Klammern weg und schreiben $(\alpha_1|\alpha_2|\dots|\alpha_n)$.

Beispiele (1)

▶ $(a|b)^*aa(a|b)^*$

erzeugt alle Wörter über $\{a, b\}$, die ?

▶ $(\epsilon|((a|b|c)^*a(a|b|c)(a|b|c)(a|b|c)))$

erzeugt alle Wörter über $\{a, b, c\}$, die ?

▶ $((0|1|2|3|4|5|6|7|8|9)|1(0|1|2|3|4|5|6|7|8|9)|(2(0|1|2|3))):$
 $((0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9))$

erzeugt alle Wörter über $\{0, 1, \dots, 9, :\}$, die ?

▶ Eine endliche Sprache $S = \{w_1, \dots, w_n\}$ wird durch ? erzeugt

Beispiele (1)

▶ $(a|b)^*aa(a|b)^*$

erzeugt alle Wörter über $\{a, b\}$, die zwei aufeinanderfolgende a 's enthalten

▶ $(\epsilon|((a|b|c)^*a(a|b|c)(a|b|c)(a|b|c)))$

erzeugt alle Wörter über $\{a, b, c\}$, die ?

▶ $((0|1|2|3|4|5|6|7|8|9)|1(0|1|2|3|4|5|6|7|8|9)|(2(0|1|2|3))):$
 $((0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9))$

erzeugt alle Wörter über $\{0, 1, \dots, 9, :\}$, die ?

▶ Eine endliche Sprache $S = \{w_1, \dots, w_n\}$ wird durch ? erzeugt

Beispiele (1)

▶ $(a|b)^*aa(a|b)^*$

erzeugt alle Wörter über $\{a, b\}$, die zwei aufeinanderfolgende a 's enthalten

▶ $(\epsilon|((a|b|c)^*a(a|b|c)(a|b|c)(a|b|c)))$

erzeugt alle Wörter über $\{a, b, c\}$, die an viertletzter Stelle ein a haben sowie das leere Wort

▶ $((0|1|2|3|4|5|6|7|8|9)|1(0|1|2|3|4|5|6|7|8|9)|(2(0|1|2|3))):$
 $((0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9))$

erzeugt alle Wörter über $\{0, 1, \dots, 9, :\}$, die ?

▶ Eine endliche Sprache $S = \{w_1, \dots, w_n\}$ wird durch ? erzeugt

Beispiele (1)

▶ $(a|b)^*aa(a|b)^*$

erzeugt alle Wörter über $\{a, b\}$, die zwei aufeinanderfolgende a 's enthalten

▶ $(\epsilon|((a|b|c)^*a(a|b|c)(a|b|c)(a|b|c)))$

erzeugt alle Wörter über $\{a, b, c\}$, die an viertletzter Stelle ein a haben sowie das leere Wort

▶ $((0|1|2|3|4|5|6|7|8|9)|1(0|1|2|3|4|5|6|7|8|9)|(2(0|1|2|3))):$
 $((0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9))$

erzeugt alle Wörter über $\{0, 1, \dots, 9, :\}$, die Uhrzeiten im 24-Stunden-Format entsprechen

▶ Eine endliche Sprache $S = \{w_1, \dots, w_n\}$ wird durch $?$ erzeugt

Beispiele (1)

▶ $(a|b)^*aa(a|b)^*$

erzeugt alle Wörter über $\{a, b\}$, die zwei aufeinanderfolgende a 's enthalten

▶ $(\epsilon|((a|b|c)^*a(a|b|c)(a|b|c)(a|b|c)))$

erzeugt alle Wörter über $\{a, b, c\}$, die an viertletzter Stelle ein a haben sowie das leere Wort

▶ $((0|1|2|3|4|5|6|7|8|9)|1(0|1|2|3|4|5|6|7|8|9)|(2(0|1|2|3))):$
 $((0|1|2|3|4|5)(0|1|2|3|4|5|6|7|8|9))$

erzeugt alle Wörter über $\{0, 1, \dots, 9, :\}$, die Uhrzeiten im 24-Stunden-Format entsprechen

▶ Eine endliche Sprache $S = \{w_1, \dots, w_n\}$ wird durch $(w_1|\dots|w_n)$ erzeugt

Beispiele (2)

Geben Sie reguläre Ausdrücke an, welche die folgenden Sprachen erzeugen:

- ▶ $L_1 =$ alle Wörter über $\{a, b\}$, die das Teilwort *abba* enthalten

- ▶ $L_2 =$ alle Wörter über $\{a, b\}$, die das Teilwort *aba* mindestens 2 Mal enthalten

- ▶ $L_3 =$ alle Wörter über $\{a, b\}$, die das Teilwort *aaa nicht* enthalten

Beispiele (2)

Geben Sie reguläre Ausdrücke an, welche die folgenden Sprachen erzeugen:

- ▶ $L_1 =$ alle Wörter über $\{a, b\}$, die das Teilwort *abba* enthalten

$$(a|b)^* abba(a|b)^*$$

- ▶ $L_2 =$ alle Wörter über $\{a, b\}$, die das Teilwort *aba* mindestens 2 Mal enthalten

- ▶ $L_3 =$ alle Wörter über $\{a, b\}$, die das Teilwort *aaa* *nicht* enthalten

Beispiele (2)

Geben Sie reguläre Ausdrücke an, welche die folgenden Sprachen erzeugen:

- ▶ $L_1 =$ alle Wörter über $\{a, b\}$, die das Teilwort $abba$ enthalten

$$(a|b)^* abba(a|b)^*$$

- ▶ $L_2 =$ alle Wörter über $\{a, b\}$, die das Teilwort aba mindestens 2 Mal enthalten

$$((a|b)^* aba(a|b)^* aba(a|b)^* \mid (a|b)^* ababa(a|b)^*)$$

- ▶ $L_3 =$ alle Wörter über $\{a, b\}$, die das Teilwort aaa *nicht* enthalten

Beispiele (2)

Geben Sie reguläre Ausdrücke an, welche die folgenden Sprachen erzeugen:

- ▶ $L_1 =$ alle Wörter über $\{a, b\}$, die das Teilwort $abba$ enthalten

$$(a|b)^* abba(a|b)^*$$

- ▶ $L_2 =$ alle Wörter über $\{a, b\}$, die das Teilwort aba mindestens 2 Mal enthalten

$$((a|b)^* aba(a|b)^* aba(a|b)^* \mid (a|b)^* ababa(a|b)^*)$$

- ▶ $L_3 =$ alle Wörter über $\{a, b\}$, die das Teilwort aaa *nicht* enthalten

$$(b|ab|aab)^*(\epsilon|a|aa)$$

Beispiel: grep

```
$ grep -E " d(er|ie|as) neue" faust.txt
Nein, er gefällt mir nicht, der neue Burgemeister!
Allein der neue Trieb erwacht,
Da seh' ich auch die neue Wohnung,
Noch blendet ihn der neue Tag.
```

```
$ grep -E "(der|die|das) Q[a-z]*" faust.txt
Von dem der Quell sich ewig sprudelnd stürzt,
Vom ganzen Praß die Quintessenz.
```

```
$ grep -E "(( )*Gretchen[[:punct:]]*){2,}" faust.txt
Gretchen! Gretchen!
```

Theorem 4.7.4 (Satz von Kleene)

Reguläre Ausdrücke erzeugen genau die regulären Sprachen.

Beweis in zwei Teilen:

1. Jede von einem regulären Ausdruck erzeugte Sprache ist regulär.
2. Für jede reguläre Sprache gibt es einen regulären Ausdruck, der sie erzeugt.