

Grundbegriffe der Informatik

Kapitel 7: formale Sprachen

Mattias Ulbrich

(basierend auf Folien von Thomas Worsch)

KIT · Institut für Theoretische Informatik

Wintersemester 2023/2024

Erinnerung: formale Sprache

- *formale Sprache über einem Alphabet A*
eine Teilmenge $L \subseteq A^*$

Wo sind wir?

Produkt formaler Sprachen

Konkatenationsabschluss formaler Sprachen

- „passend“ zur Definition bei Wörtern
- Produkt der Sprachen L_1 und L_2 :

$$L_1 \cdot L_2 = \{w_1w_2 \mid w_1 \in L_1 \text{ und } w_2 \in L_2\}$$

- wegen der Assoziativität der Konkatenation von Wörtern auch

$$L_1 \cdot L_2 \cdot L_3 = \{w_1w_2w_3 \mid w_1 \in L_1 \text{ und } w_2 \in L_2 \text{ und } w_3 \in L_3\}$$

- den Punkt lässt man auch gerne wieder weg

- wenn $L_1 = \{a\}$ und $L_2 = \{b\}$
dann $L_1 \cdot L_2 = \{a\} \cdot \{b\}$
 $= \{a \cdot b\}$
 $= \{ab\}$

- wenn $L_1 = \{a\}$ und $L_2 = \{b\}$
dann $L_1 \cdot L_2 = \{a\} \cdot \{b\}$
 $= \{a \cdot b\}$
 $= \{ab\}$
- wenn $L_1 = \{a\}$ und $L_2 = \{b, ab\}$
dann $L_1 \cdot L_2 = \{a\} \cdot \{b, ab\}$
 $= \{a \cdot b, a \cdot ab\}$
 $= \{ab, aab\}$

- wenn $L_1 = \{a\}$ und $L_2 = \{b\}$
dann $L_1 \cdot L_2 = \{a\} \cdot \{b\}$
 $= \{a \cdot b\}$
 $= \{ab\}$
- wenn $L_1 = \{a\}$ und $L_2 = \{b, ab\}$
dann $L_1 \cdot L_2 = \{a\} \cdot \{b, ab\}$
 $= \{a \cdot b, a \cdot ab\}$
 $= \{ab, aab\}$
- wenn $L_1 = \{a, aa\}$ und $L_2 = \{b, ab\}$
dann $L_1 \cdot L_2 = \{a, aa\} \cdot \{b, ab\}$
 $= \{a \cdot b, a \cdot ab, aa \cdot b, aa \cdot ab\}$
 $= \{ab, aab, aaab\}$

- betrachte ASCII-Alphabet und Sprachen
 $S = \{\text{int}, \text{double}, \text{char}\}$,
 $B = \{\text{a}, \dots, \text{z}\}$ und
 $Z = \{0, \dots, 9\}$
- $S \cdot \{_ \} \cdot B \cdot (B \cup Z \cup \{\varepsilon\}) \cdot \{;\}$

- betrachte ASCII-Alphabet und Sprachen

$S = \{\text{int}, \text{double}, \text{char}\}$,

$B = \{\text{a}, \dots, \text{z}\}$ und

$Z = \{0, \dots, 9\}$

- $S \cdot \{_ \} \cdot B \cdot (B \cup Z \cup \{\varepsilon\}) \cdot \{;\}$
enthält „Deklarationen“ wie z. B.

- `int_x2;`

- `double_w;`

- betrachte ASCII-Alphabet und Sprachen

$S = \{\text{int}, \text{double}, \text{char}\}$,

$B = \{\text{a}, \dots, \text{z}\}$ und

$Z = \{0, \dots, 9\}$

- $S \cdot \{_ \}$ · $B \cdot (B \cup Z \cup \{\varepsilon\}) \cdot \{;\}$
enthält „Deklarationen“ wie z. B.

- `int_x2;`

- `double_w;`

aber leider nicht

- `char_hugo_;`

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$L \cdot \{\varepsilon\} = \{w_1w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\}$$

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$\begin{aligned} L \cdot \{\varepsilon\} &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\} \\ &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 = \varepsilon\} \end{aligned}$$

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$\begin{aligned} L \cdot \{\varepsilon\} &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\} \\ &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 = \varepsilon\} \\ &= \{w_1 \varepsilon \mid w_1 \in L\} \end{aligned}$$

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$\begin{aligned} L \cdot \{\varepsilon\} &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\} \\ &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 = \varepsilon\} \\ &= \{w_1 \varepsilon \mid w_1 \in L\} \\ &= \{w_1 \mid w_1 \in L\} \end{aligned}$$

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$\begin{aligned} L \cdot \{\varepsilon\} &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\} \\ &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 = \varepsilon\} \\ &= \{w_1 \varepsilon \mid w_1 \in L\} \\ &= \{w_1 \mid w_1 \in L\} \\ &= L \end{aligned}$$

Lemma

- Für jede formale Sprache L ist

$$L \cdot \{\varepsilon\} = L = \{\varepsilon\} \cdot L .$$

Beweis

- einfaches Nachrechnen:

$$\begin{aligned} L \cdot \{\varepsilon\} &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 \in \{\varepsilon\}\} \\ &= \{w_1 w_2 \mid w_1 \in L \text{ und } w_2 = \varepsilon\} \\ &= \{w_1 \varepsilon \mid w_1 \in L\} \\ &= \{w_1 \mid w_1 \in L\} \\ &= L \end{aligned}$$

Analog zeigt man $L = \{\varepsilon\} \cdot L$.

Potenzen von Sprachen — wie bei Wörtern induktiv definiert

- „Problem“: Was soll L^0 sein?

Potenzen von Sprachen — wie bei Wörtern induktiv definiert

- „Problem“: Was soll L^0 sein?
- Definiere:

$$L^0 = \{\varepsilon\}$$
$$\forall n \in \mathbb{N}_0 : L^{n+1} = L \cdot L^n$$

Potenzen von Sprachen — wie bei Wörtern induktiv definiert

- „Problem“: Was soll L^0 sein?
- Definiere:

$$L^0 = \{\varepsilon\}$$

$$\forall n \in \mathbb{N}_0 : L^{n+1} = L \cdot L^n$$

- Nachrechnen ergibt z. B. $L^1 = L$
 $L^2 = L \cdot L$
 $L^3 = L \cdot L \cdot L$
- Genau genommen: $L^3 = L \cdot (L \cdot L)$, aber:
Konkatenation von Sprachen ist eine assoziative Operation.

- $L = \{aa, b\}$
- Dann ist

$$L^0 = \{\varepsilon\}$$

$$L^1 = \{aa, b\}$$

$$\begin{aligned} L^2 &= \{aa, b\} \cdot \{aa, b\} = \{aa \cdot aa, aa \cdot b, b \cdot aa, b \cdot b\} \\ &= \{aaaa, aab, baa, bb\} \end{aligned}$$

$$\begin{aligned} L^3 &= \{aa \cdot aa \cdot aa, aa \cdot aa \cdot b, aa \cdot b \cdot aa, aa \cdot b \cdot b, \\ &\quad b \cdot aa \cdot aa, b \cdot aa \cdot b, b \cdot b \cdot aa, b \cdot b \cdot b\} \\ &= \{aaaaaa, aaaab, aabaa, aabb, \\ &\quad baaaa, baab, bbaa, bbb\} \end{aligned}$$

- Sei

$$L = \{a^n b^n \mid n \in \mathbb{N}_+\},$$

also sozusagen (immer diese Pünktchen ...)

$$L = \{ab, aabb, aaabbb, aaaabbbb, \dots\}.$$

- Was ist $L^2 = L \cdot L$?

$$\begin{aligned} \blacksquare L^2 = & \{ab \cdot ab, ab \cdot aabb, ab \cdot aaabbb, \dots\} \\ & \cup \{aabb \cdot ab, aabb \cdot aabb, aabb \cdot aaabbb, \dots\} \\ & \cup \{aaabbb \cdot ab, aaabbb \cdot aabb, aaabbb \cdot aaabbb, \dots\} \\ & \cup \dots \end{aligned}$$

- Sei

$$L = \{a^n b^n \mid n \in \mathbb{N}_+\},$$

also sozusagen (immer diese Pünktchen ...)

$$L = \{ab, aabb, aaabbb, aaaabbbb, \dots\}.$$

- Was ist $L^2 = L \cdot L$?

- $L^2 = \{ab \cdot ab, ab \cdot aabb, ab \cdot aaabbb, \dots\}$
 $\cup \{aabb \cdot ab, aabb \cdot aabb, aabb \cdot aaabbb, \dots\}$
 $\cup \{aaabbb \cdot ab, aaabbb \cdot aabb, aaabbb \cdot aaabbb, \dots\}$
 $\cup \dots$

- also $L^2 = \{a^{n_1} b^{n_1} a^{n_2} b^{n_2} \mid n_1 \in \mathbb{N}_+ \text{ und } n_2 \in \mathbb{N}_+\}.$

- Exponenten n_1 und n_2 können verschieden sein

- für Alphabet A schon Potenzen A^i definiert.
- Jedes Alphabet A kann man als formale Sprache L_A auffassen
 - enthält alle Wörter der Länge 1
- Man mache sich klar:
 A^i ist «das Gleiche» wie L_A^i .

Wo sind wir?

Produkt formaler Sprachen

Konkatenationsabschluss formaler Sprachen

Konkatenationsabschluss von L — beliebig viele Faktoren aus L

- bei Alphabeten: $A^* = \bigcup_{i \in \mathbb{N}_0} A^i$.
- **Konkatenationsabschluss L^*** von L (kleenesche Hülle, Kleene Star)

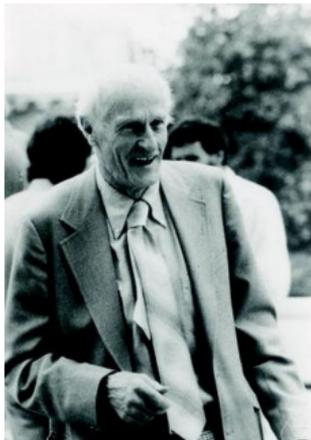
$$L^* = \bigcup_{i \in \mathbb{N}_0} L^i$$

- **ε -freier Konkatenationsabschluss L^+** von L (Kleene-+-Abschluss)

$$L^+ = \bigcup_{i \in \mathbb{N}_+} L^i$$

- Man sieht:

$$L^* = L^0 \cup L^+ .$$



- geboren 5. Januar 1909 in Hartford, CT, USA
gestorben am 25. Januar 1994 in Madison, WI, USA
- einer der Begründer der theoretischen Informatik
- insbesondere: formale Sprachen, kleenesche Hülle, Lambda-Kalkül, reguläre Ausdrücke

Bildquelle [https://commons.wikimedia.](https://commons.wikimedia.org/wiki/File:Kleene.jpg)

[org/wiki/File:Kleene.jpg](https://commons.wikimedia.org/wiki/File:Kleene.jpg)

CC BY-SA 4.0

- Es sei wieder $L = \{a^n b^n \mid n \in \mathbb{N}_+\}$.
- schon gesehen
 $L^2 = \{a^{n_1} b^{n_1} a^{n_2} b^{n_2} \mid n_1 \in \mathbb{N}_+ \text{ und } n_2 \in \mathbb{N}_+\}$
- analog
 $L^3 = \{a^{n_1} b^{n_1} a^{n_2} b^{n_2} a^{n_3} b^{n_3} \mid n_1 \in \mathbb{N}_+ \text{ und } n_2 \in \mathbb{N}_+ \text{ und } n_3 \in \mathbb{N}_+\}$
- mit Pünktchen ...
 $L^i = \{a^{n_1} b^{n_1} \dots a^{n_i} b^{n_i} \mid n_1, \dots, n_i \in \mathbb{N}_+\}$
- Dann kann man für L^+ notieren
 $L^+ = \{a^{n_1} b^{n_1} \dots a^{n_i} b^{n_i} \mid i \in \mathbb{N}_+ \text{ und } n_1, \dots, n_i \in \mathbb{N}_+\}$
- L^+ und L^* sind *präziser und kürzer* als viele Pünktchen

Beispiele für Konkatenationsabschluss (2)

$$A = \{a, b\}$$

- $L = \{a\}^* \cup \{b\}^* = \{\varepsilon, a, aa, aaa, \dots, b, bb, bbb, \dots\}$
- Welche Wörter enthält $L^* = (\{a\}^* \cup \{b\}^*)^*$?
 - alle Wörter, die man erhält, wenn man
 - eine beliebige endliche Zahl k
 - von Wörtern w_1, \dots, w_k aus L
 - konkateniert zu $w_1 \cdots w_k$
 - z. B. $aa \cdot \varepsilon \cdot aaaa \cdot b \cdot aaaaa$
 - z. B. $aa \cdot bbbb \cdot aaa \cdot b \cdot aaaaa \cdot bbb \cdot aaa$

$$A = \{a, b\}$$

- $L = \{a\}^* \cup \{b\}^* = \{\varepsilon, a, aa, aaa, \dots, b, bb, bbb, \dots\}$
- Welche Wörter enthält $L^* = (\{a\}^* \cup \{b\}^*)^*$?
 - alle Wörter, die man erhält, wenn man
 - eine beliebige endliche Zahl k
 - von Wörtern w_1, \dots, w_k aus L
 - konkateniert zu $w_1 \cdots w_k$
 - z. B. $aa \cdot \varepsilon \cdot aaaa \cdot b \cdot aaaaa$
 - z. B. $aa \cdot bbbb \cdot aaa \cdot b \cdot aaaaa \cdot bbb \cdot aaa$
- Beobachtung
 - jedes Wort aus A^* ist die Konkatenation von Blöcken, die nur aus a oder nur aus b bestehen
 - also ist $L^* = A^*$

- wenn
 - $S = \{\text{int, double, char}\}$
 - $B = \{\text{a, \dots, z}\}$
 - $Z = \{0, \dots, 9\}$

- dann enthält

$$S \cdot \{_ \}^+ \cdot B \cdot (B \cup Z)^* \cdot \{_ \}^* \cdot \{;\}$$

„Deklarationen“ wie z. B.

- `int__x42__;`
- `double__wurzelzwei;`

- wenn
 - $S = \{\text{int, double, char}\}$
 - $B = \{\text{a, \dots, z}\}$
 - $Z = \{0, \dots, 9\}$

- dann enthält

$$S \cdot \{_ \}^+ \cdot B \cdot (B \cup Z)^* \cdot \{_ \}^* \cdot \{;\}$$

„Deklarationen“ wie z. B.

- `int_x42_;`
- `double_wurzelzwei;`
- aber leider auch
 - `int_double;` usw.

- L^+ „ ε -freier“ Konkatenationsabschluss: irreführend
- klar ist:

$$\varepsilon \in L^0 \subseteq L^*$$

- aber: $L = L^1 \subseteq L^+$,
wenn also $\varepsilon \in L$, dann auch $\varepsilon \in L^+$.

- L^+ „ ε -freier“ Konkatenationsabschluss: irreführend
- klar ist:

$$\varepsilon \in L^0 \subseteq L^*$$

- aber: $L = L^1 \subseteq L^+$,
wenn also $\varepsilon \in L$, dann auch $\varepsilon \in L^+$.

- Beachte

$$\{\}^* = \{\varepsilon\}$$

- Das sollten Sie mitnehmen:
 - was formale Sprachen sind,
 - wie ihr Produkt definiert ist und
 - wie Konkatenationsabschluss und ε -freier Konkatenationsabschluss definiert sind.
- Das sollten Sie üben:
 - Erkennen von Strukturen der Form L^* , L^+ , L_1L_2
 - Lesen von Ausdrücken der Form $(L_1^+L_2)^*$ usw.
 - „Rechnen“ mit formalen Sprachen