Automatentheorie und Formale Sprachen

Vorlesung

Di 11:45 – 13:15 Fo 2	Beginn	Prof. Dr. K. Indermark
Fr 10:45 – 11:30 Gr	20.4. (2h)	Sprechstunde n. Vereinb.

Zentralübung

Fr 10:00 – 10:45 Gr	Beginn	B. Bollig
	27.4.	Sprechstunde n. Vereinb.

Diskussionsgruppen (Beginn: 23.4.)

Mo 08:15 - 09:45 SG 12,
Mo 10:00 - 11:30 SG 413,
Mo 10:00 - 11:30 SG 512,
Mo 11:45 - 13:15 SG 413,
Mo 11:45 - 13:15 **AH III** (23.4., 30.4., 7.5.), **5052** (ab 14.5.)
Gruppenleiter: Patrick Hütten, Philipp Lucas,
Carsten Pelikan, Björn Riedel, Nico Wallmeier

Übungsschein

- 50% der erreichbaren Punkte bei den Übungsaufgaben
- Übungsscheinklausur (Mi, 18.7.2001, 15:00 – 17:00 Uhr)
- Abgabe der Lösungen maximal zu zweit

Aufgaben

- Ausgabe: freitags vor der Zentralübung (1. Blatt: 20.4.)
- Abgabe: freitags vor der Zentralübung (1. Blatt: 27.4.)

Vordiplomsklausur

- Informatik III, Teilprüfung ATFS
- Fr, 17.8.2001, Aula 2, AH IV, AH V, 9:00 – 12:00 Uhr
- Rechtzeitige Anmeldung im ZPA!

Web-Seite zur Vorlesung:

www-i2.informatik.rwth-aachen.de/Vorlesung/ATFS01/

- Folien
- Übungsblätter
- Literaturliste
- Aktuelles

Fortsetzung der Vorlesung

Berechenbarkeit und Komplexität (WS 2000/01), Prof. Thomas

- Algorithmenbegriff und Turingmaschinen
- WHILE- und GOTO-Programme
- Unentscheidbarkeit
- Zeit- und Platzkomplexität

Inhalt der Vorlesung

- Endliche Automaten und reguläre Sprachen
- Kellerautomaten und kontextfreie Sprachen
- Turingmaschinen und aufzählbare Sprachen

Literatur

- U. Schöning, *Theoretische Informatik kurz gefaßt*, Spektrum-Akademischer Verlag, 3. Auflage, 1997
- I. Wegener, *Theoretische Informatik*, Teubner, 2. Auflage, 1999
- K.W. Wagner, *Einführung in die Theoretische Informatik*, Springer Verlag, 1994
- J.E. Hopcroft, R. Motwani, J.D. Ullmann, *Introduction to Automata Theory, Languages, and Computation*, 2nd ed., Addison-Wesley, 2001
- J. v. Leeuwen, *Handbook of Theoretical Computer Science*, 2 Bände, Elsevier, 1990

Die griechische Wurzel des Wortes „Theorie“ heißt „sehen“. Gut ausgewählte, verständlich dargestellte Theorie dient uns als Lupe und Fernrohr, um Tatbestände zu sehen, die von bloßem Auge unsichtbar sind.

aus: Nievergelt, Informatik-Spektrum 18 (1995), 342-344

Alphabete

$$
\begin{array}{lcl}
\Sigma_{\text{bin}} & = & \{0,1\} \\
\Sigma_{\text{dec}} & = & \{0,1,\ldots,9\} \\
\Sigma_{\text{hex}} & = & \Sigma_{\text{dec}} \cup \{\text{A,B,C,D,E,F}\} \\
\Sigma_{\text{let}} & = & \{\text{a,b},\ldots,\text{z,A,B},\ldots,\text{Z}\} \\
\Sigma_{\text{ascii}} & = & \text{ASCII-Zeichensatz} \quad \text{(7-Bit)} \\
\Sigma_{\text{latin1}} & = & \text{Latin1-Zeichensatz (enthält ñ, Ñ) (8-Bit)} \\
\Sigma_{\text{unicode}} & = & \{\backslash\mathtt{u}h_1h_2h_3h_4 \mid h_i \in \Sigma_{\text{hex}}\} \text{ (Java) (16-Bit)} \\
\Sigma_{\text{sym}} & = & \{\ldots, <, =, >, <=, :=, ->, \mathtt{if}, \mathtt{while}, \ldots\}
\end{array}
$$

Inhalt der Vorlesung

effektive Beschreibung formaler Sprachen durch

- reguläre Ausdrücke (RegE)
- nichtdeterministische endliche Automaten (NFA)
- deterministische endliche Automaten (DFA)

- kontextfreie Grammatiken (CFG)
- nichtdeterministische Kellerautomaten (PDA)
- deterministische Kellerautomaten (DPDA)

- Chomsky-Grammatiken vom Typ i (CG_i)
  für $i = 0, 1, 2, 3$
- nichtdeterministische Turingmaschinen (TM)
- deterministische Turingmaschinen (DTM)

- linear beschränkte Automaten (LBA)

Chomsky-Hierarchie

Für eine Sprachbeschreibung D sei $L(D)$ die beschriebene Sprache.

Für eine Beschreibungsklasse Δ sei

$$\mathcal{L}(\Sigma, \Delta) := \{L \subseteq \Sigma^* \mid \exists D \in \Delta : \; L = L(D)\}$$

die entsprechende Sprachklasse.

$$\begin{array}{ll}
 & \mathcal{L}(\Sigma, \mathrm{CG}_3) = \mathcal{L}(\Sigma, \mathrm{RegE}) = \mathcal{L}(\Sigma, \mathrm{NFA}) \; = \mathcal{L}(\Sigma, \mathrm{DFA}) \\
\subsetneq & \mathcal{L}(\Sigma, \mathrm{CG}_2) = \mathcal{L}(\Sigma, \mathrm{PDA}) \\
\subsetneq & \mathcal{L}(\Sigma, \mathrm{CG}_1) = \mathcal{L}(\Sigma, \mathrm{LBA}) \\
\subsetneq & \mathcal{L}(\Sigma, \mathrm{CG}_0) = \mathcal{L}(\Sigma, \mathrm{TM}) \quad = \mathcal{L}(\Sigma, \mathrm{DTM})
\end{array}$$

Grundprobleme von Beschreibungen

Sei Δ eine Beschreibungsklasse von Σ-Sprachen.

1) Das **Wortproblem** für Δ (WP(Δ)):
   Gibt es ein Verfahren, welches für $w \in \Sigma$ und $D \in \Delta$ feststellt, ob $w \in L(D)$ oder $w \notin L(D)$?

2) Das **Äquivalenzproblem** für Δ (ÄP(Δ)):
   Gibt es ein Verfahren, welches für $D_1, D_2 \in \Delta$ feststellt, ob $L(D_1) = L(D_2)$ oder $L(D_1) \neq L(D_2)$?

   Bez.: $D_1 \sim D_2$ („äquivalent“):$\curvearrowright$ $L(D_1) = L(D_2)$

3) Das **Leerheitsproblem** für Δ (LP(Δ)):
   Gibt es ein Verfahren, welches für $D \in \Delta$ feststellt, ob $L(D) = \emptyset$ oder $L(D) \neq \emptyset$?

Entscheidbarkeit dieser Probleme für Chomsky-Grammatiken

	WP	LP	ÄP
CG_3	+	+	+
CG_2	+	+	–
CG_1	+	–	–
CG_0	–	–	–

Inhalt

- Beschreibung formaler Sprachen durch reguläre Ausdrücke
- Erkennung durch nicht-det. und det. endliche Automaten
- Synthese und Analyse endlicher Automaten
- Zustandsreduktion endlicher Automaten
- Wortproblem, Äquivalenzproblem, Leerheitsproblem
- Anwendungen

UNIX-Notation für reguläre Ausdrücke

Σ =ASCII-Zeichensatz

`.`	$:=$	$a_1 \vee \ldots \vee a_n$ mit $\{a_1, \ldots, a_n\} = \Sigma$
`[abc]`	$:=$	$\mathtt{a} \vee \mathtt{b} \vee \mathtt{c}$
`[0-9]`	$:=$	$\mathtt{0} \vee \mathtt{1} \vee \ldots \vee \mathtt{9}$
`[A-Za-z0-9]`	$:=$	$\mathtt{A} \vee \ldots \vee \mathtt{Z} \vee \mathtt{a} \vee \ldots \vee \mathtt{z} \vee \mathtt{0} \vee \ldots \vee \mathtt{9}$
`[:digit:]`	$:=$	`[0-9]`
`[:alpha:]`	$:=$	`[A-Za-z]`
`()`	$:=$	Λ^*
$\alpha\beta$	$:=$	$\alpha \cdot \beta$
$\alpha \vert \beta$	$:=$	$\alpha \vee \beta$
α`*`	$:=$	α^*
α`+`	$:=$	$\alpha\alpha^*$
α`?`	$:=$	$\Lambda^* \vert \alpha$
$\alpha\{3\}$	$:=$	$\alpha\alpha\alpha$
$\alpha\{3{,}5\}$	$:=$	$\alpha\{3\} \vert \alpha\{4\} \vert \alpha\{5\}$

Ausführliche Beschreibung im Manual unter

```
> man 7 regex
```

(reg. expr. as defined in POSIX 1003.2)

Anwendungen

1) Symbolklassen von PS: Bezeichner,Zahlwörter,...

   Fließkommazahlen in C:

   ```
   ExpPart     = [eE][-+]?[0-9]+
   FractConst  = ([0-9]*\.[0-9]+)|([0-9]+\.)
   FloatConst  = ((({FractConst})({ExpPart})?)|
                  ([0-9]+{ExpPart}))[FfLl]?
   ```

2) Textsuche:

   `> egrep 'Gr(ae|ä)del' publications.txt`

   Ausgabe von Zeilen, die einen Match enthalten

   Besonderheit: $\hat{}\alpha$ Match von α am Zeilenanfang

   $\alpha\$$ Match von α am Zeilenende

3) Transformation von Texten mit Perl (Systemverwaltung)

4) Suchmaschinen für Web-Dokumente

Standardprobleme für RegE(Σ)

1) **Wortproblem** (matching problem):
   Sei $w \in \Sigma^*$ und $\alpha \in \mathrm{RegE}(\Sigma)$. Ist w ein *Match* von α, also $w \in [\![\alpha]\!]$?
   Oder allgemeiner: Enthält w einen Match von α, d.h. ist w zerlegbar in $w = u_1 v u_2$ mit $v \in [\![\alpha]\!]$?

2) **Äquivalenzproblem**:
   Gilt $[\![\alpha]\!] = [\![\beta]\!]$ für $\alpha, \beta \in \mathrm{RegE}(\Sigma)$?
   Schreibweise: $\alpha \sim \beta :\curvearrowleftright [\![\alpha]\!] = [\![\beta]\!]$
   Beispiel: $\alpha^* \sim \Lambda^* \vee \alpha\alpha^*$

3) **Leerheitsproblem**:
   Gilt $[\![\alpha]\!] = \emptyset$ für $\alpha \in \mathrm{RegE}(\Sigma)$?