# Kapitel 2

## Lexikalische Analyse

# Kapitel 2: Lexikalische Analyse


1 Eingliederung in den Übersetzer / Zielvorgaben

2 Theoretische Grundlage: Endliche Automaten

3 Implementierung
- Implementierung endlicher Automaten, Tabellenkompression
- Der Tokenstrom
- Implementierung der Stringtabelle

4 Einsatz von Generatoren
- Flex

# lexikalische Analyse: Aufgabe

- zerlegt Quellprogramm (*Text*) in Sequenz bedeutungstragender Einheiten (*Tokenstrom*)
- beseitigt überflüssige Zeichen(folgen) wie
  - Kommentare,
  - Leerzeichen, Tabulatoren usw.
- Modell: endlicher Automat aus programmiertechnischen Gründen: Geschwindigkeit höher


KIT Karlsruhe Institute of Technology

# Eingliederung in den Übersetzer

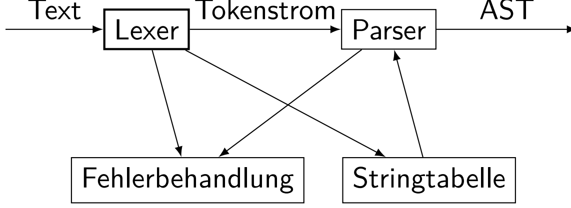

# Warum getrennte lexikalische Analyse?

- Durchschnittliche Komplexität einer Anweisung (Knuth und andere[1]):

  **var** := **var** + **const**;

  const $\in \{-1, 0, 1\}$
- 6 Symbole, aber ca. 40–60 Zeichen, viele (10–40) Leerzeichen pro Zeile wegen Einrückungen und Kommentaren
  - Informationskompression größer als in allen anderen Teilen des Übersetzers
  - deshalb Abtrennung
  - Aber: Kompression nur in Anzahl Symbolen, nicht unbedingt in Anzahl Bytes!
- Heute Geschwindigkeit der lexikalischen Analyse eher unrelevant ($<$5% der Compilerlaufzeit).
- Trennung aber Softwaretechnisch sinnvoll: Entkopplung, Modularisierung.

[1] D.E. Knuth: An Empirical Study of FORTRAN Programs, Software P&E, 1(1971), 105-134

# Weitere Gründe

- Beobachtung zeigt, dass bei modernen Programmiersprachen endliche Automaten ausreichen
- Umfangreiche Eingabe, daher effiziente Hilfsmittel (endl. Automat schneller als Kellerautomat)
- Sich selbst erfüllende Prophezeiung:
  Weil endliche Automaten ausreichen, sind moderne Programmiersprachen so formuliert, dass endliche Automaten ausreichen.
- Ausnahmen:
  - endl. Automat mit Rücksetzen am Ende:
    1.E1 → 1.E1,
    1.EQ. → 1 .EQ.,
    else 1. E...
    (Fortran, other languages: +:=,=:=,...)
  - mehrere Automaten, gesteuert vom Parser: Fortran Formate (Text ohne Anführungszeichen!)

Beim Sprachentwurf: Unabhängigkeit Lexer/Parser als Ziel

# Beispiel: Ausnahmen

- Fortran 77
  READ 5,ggg,...
  ggg ist eine Formatanweisung, kein Bezeichner
- C
  #pragma ...
  Pragma in C: ... kann beliebiges enthalten; ist also insbesondere nicht im Sprachstandard definiert
- Pascal
  (∗D ...∗)
  Pragma in Pascal
- Zeichenketten in vielen Programmiersprachen

# ADT Lexer

Gelieferte Operationen:

- `next_token`

Benötigte Operationen:

Eingabe:

- `next_char` oder `read_file`

Stringtabelle:

- `insert(text, key)`
- `find_or_insert(text) : (key,value)`
- `get_text(key) : text`

Fehlerbehandlung:

- `add_error(nr,text)`

# Automat für Float-Konstanten in C[2]

## Regulärer Ausdruck

$$((\mathbf{0} + \ldots + \mathbf{9})^{*}\mathbf{.}(\mathbf{0} + \ldots + \mathbf{9})^{+}) + ((\mathbf{0} + \ldots + \mathbf{9})^{+}\mathbf{.})$$

$$(\varepsilon + ((\mathbf{e} + \mathbf{E})(\mathbf{+} + \mathbf{-} + \varepsilon)(\mathbf{0} + \ldots + \mathbf{9})^{+}))(\varepsilon + \mathbf{f} + \mathbf{F} + \mathbf{l} + \mathbf{L})$$

## Automat

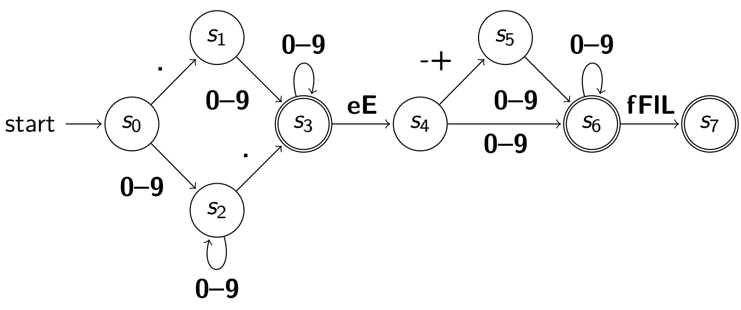


[2] siehe ISO/IEC 9899:1999 §6.4.4.2

# Tokenidentifikation

Token können identifiziert werden durch:

- Endzustand im Automaten (für jedes Token ein eigener Endzustand)
- Stringtabellen (durch Vergleich mit deren Einträgen)
- Hybrider Ansatz
  - Wortsymbole (z.B. „if“, „class“) und Bezeichner (z.B. Variablen- oder Funktionsnamen) erst in Stringtabelle unterschieden
  - andere Tokens mit unterschiedlichen Endzuständen

# Prinzip des längsten Musters

Wann hört der Automat auf?

- Prinzip: der Automat liest immer so weit, bis das gelesene Zeichen nicht mehr zum Token gehören kann
  - bei Bezeichnern: bis ein Zeichen erreicht ist, das kein Buchstabe oder Ziffer (oder Unterstrich, ...) ist
- Konsequenz: der Automat startet mit dem Zeichen, das er beim Vorgängertoken als letztes las
  - *Grundzustand: ein Zeichen im Puffer*

# Zielvorgaben

- soll höchstens 6%–10% der Gesamtlaufzeit eines nicht-optimierenden Übersetzers benötigen
- 15% einschl. syntaktischer Analyse
- Hauptaufwand: Einlesen der Quelle
  - zeichenweise: zu langsam wegen Prozeduraufruf/Systemaufruf für jedes gelesene Zeichen, nur bei Lesen von Tastatur
  - zeilenweise: Zeilen unbeschränkter Länge bei generiertem Code!? doppeltes Lesen wegen Suche nach Zeilenwechsel, mehrfaches Kopieren von Puffern
  - gepufferte Eingabe
  - Heutzutage: komplette Datei in virtuellen Hauptspeicher: hoher Speicherbedarf bei vielen offenen Dateien

# Implementierung der zeichenweise Eingabe (1/2)

- Verwende 2 Puffer der Größe $N$ (z.B. 4096 Byte)

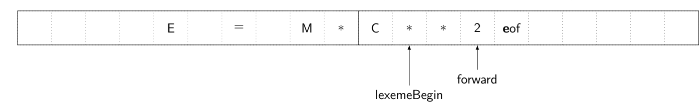


- lexemeBegin zeigt auf Begin des aktuellen Strings
- forward zeigt auf aktuelles Zeichen
- Verwende zusätzliche Wächter um Überlauf zu erkennen

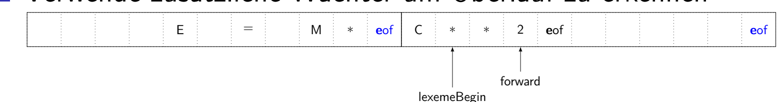

# Implementierung der zeichenweise Eingabe (2/2)

```
switch (*forward++) {
    case eof:
        if (forward is at end of first buffer) {
            reload second buffer;
            forward = beginning of second buffer;
        }
        else if (forward is at end of second buffer) {
            reload first buffer;
            forward = beginning of first buffer;
        }
        else /* eof within a buffer marks the end of input */
            terminate lexical analysis;
        break;
    /* Cases for the other characters */
}
```

# Lexikalische Analyse in Fortran 77

## Problem

- Zwischenräume können auch in Symbolen vorkommen,
- Symboleinteilung abhängig davon, ob Anweisung mit Wortsymbol beginnt
- Dies kann erst später entschieden werden:
  - DO 10 I = 1.5 ist Zuweisung an Variable DO10I
  - DO10I = 1,5 ist Schleifensteuerung (Zähler I, Endmark 10)

## Verfahren

- Lies gesamte Anweisung. Anweisung beginnt mit Wortsymbol, wenn
  - Anweisung kein Gleichheitszeichen (außerhalb von Klammern) enthält
  - nach einem Gleichheitszeichen ein Komma (außerhalb von Klammern) folgt
  - ...
- Andernfalls ist die Anweisung eine Zuweisung, beginnend mit einem Bezeichner

# Kapitel 2: Lexikalische Analyse


1 Eingliederung in den Übersetzer / Zielvorgaben

2 Theoretische Grundlage: Endliche Automaten

3 Implementierung
- Implementierung endlicher Automaten, Tabellenkompression
- Der Tokenstrom
- Implementierung der Stringtabelle

4 Einsatz von Generatoren
- Flex

# Definition endlicher Automat

Ein endlicher Automat $A$ ist ein Quintupel $(S, \Sigma, \delta, s_0, F)$, so dass:

- $\Sigma$ ist das Eingabealphabet, eine endliche Menge von Symbolen
- $S \neq \emptyset$ ist eine endliche Menge von Zuständen
- Anfangszustand $s_0 \in S$
- $F \subseteq S$ sind die Endzustände
- $\delta : S \times \Sigma \to 2^S$ Übergangsrelation
- Elemente in $\delta$: $sx \to s'$; $s \in S$, $x \in \Sigma$, $s' \in 2^S$

$A$ akzeptiert die Zeichenketten $L(A) = \{\tau \in \Sigma^* | s_0\tau \to^* s, s \in F\}$.
Die Automaten $A, A'$ sind äquivalent gdw. $L(A) = L(A')$.
$A$ ist deterministisch, wenn $\delta$ eine (partielle) Funktion ist, d. h. zu jedem Zustand und jeder Eingabe höchstens ein Folgezustand existiert.

# Reguläre Ausdrücke

Gegeben: Vokabular $V$ sowie die Symbole $\varepsilon, +, \ *, (, ), [, ]$, die nicht in $V$ enthalten sind. Eine Zeichenkette $R$ über $V$ ist ein regulärer Ausdruck über $V$, wenn:

- $R$ ist ein einziges Zeichen aus $V$ oder Symbol $\varepsilon$, oder
- $R$ hat die Form $(X), X + Y, XY, X^*, X^+, [X]_m^n$, wobei $X$ und $Y$ reguläre Ausdrücke sind
- Klammern können weggelassen werden: $^*$ hat höchste Priorität, $^+$ eine niedrigere als Konkatenation.

**Satz:**
Für jeden regulären Audruck $R$ existiert ein endlicher Automat $A$, so dass $L(A) = L(R)$.

# Beispiel: Konstruktion eines endlichen Automaten

Regulärer Ausdruck:
$(b((b+z))^*)$
Einfügen von Zuständen:
${}_0(b_1((b_2+z_3))^*)$
Übergangsregeln zwischen allen benachbarten Zuständen:
$0b \to 1,\ 1b \to 2,\ 1z \to 3,\ 2\varepsilon \to 1,\ 3\varepsilon \to 1$

Hinweis: Es ist auch möglich die $\varepsilon$-Übergänge sofort zu eleminieren. (vgl. Vorlesungen über Informatik, Band 1, S. 91ff.)

# Beispiel: Endlicher Automat

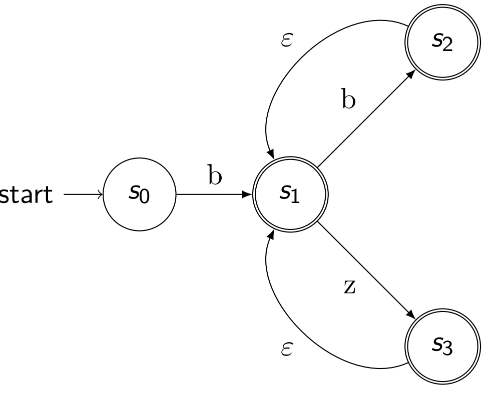


Endzustand Durchgangszustand start Startzustand


KIT Karlsruhe Institute of Technology

# Automat für Float-Konstanten in C[3]

## Regulärer Ausdruck

$$((\mathbf{0}+\ldots+\mathbf{9})^*\mathbf{.}(\mathbf{0}+\ldots+\mathbf{9})^+)+((\mathbf{0}+\ldots+\mathbf{9})^+\mathbf{.})$$
$$(\varepsilon+((\mathbf{e}+\mathbf{E})(\mathbf{+}+\mathbf{-}+\varepsilon)(\mathbf{0}+\ldots+\mathbf{9})^+))(\varepsilon+\mathbf{f}+\mathbf{F}+\mathbf{l}+\mathbf{L})$$

## Automat

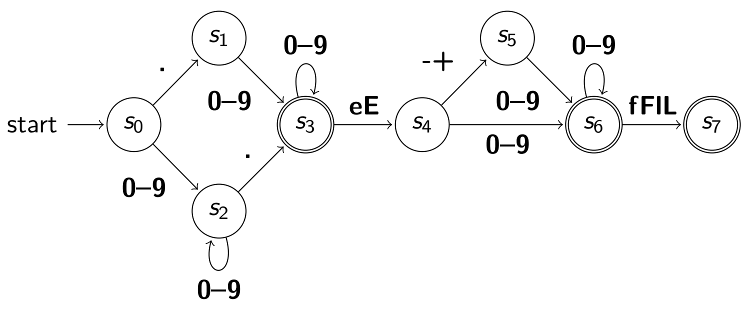


[3]siehe ISO/IEC 9899:1999 §6.4.4.2

# Teilmengenkonstruktion

- *Teilmengenkonstruktion macht endl. Automaten deterministisch*
- Zustände in $A'$ sind Mengen von Zuständen in $A$
  - Initial: $s'_0 = \{s_0\}$
  - $\varepsilon$-Übergänge:
    Wenn $s_i\varepsilon \rightarrow_A s_j$ und $s_i \in s'$ dann $s' := s' \cup \{s_j\}$
  - Sonstige Übergänge:
    Füge für jeden Zustand $s'$ und jedes Zeichen $a$ den Übergang $s'a \rightarrow_{A'} \{p_j \mid \exists s_i \in s' : s_i a \rightarrow_A p_j\}$ ein
  - Endzustände:
    Wenn $s_i \in s'_E$ Endzustand in $A$ dann $s'_E$ Endzustand in $A'$
- Komplexität praktisch linear, theoretisch (in pathologischen Fällen) exponentiell.
- pathologisch z.B.: $(a+b)^*a(a+b)^{n-1}$

# Beispiel: Teilmengenkonstruktion

Nichtdeterministischer Automat:

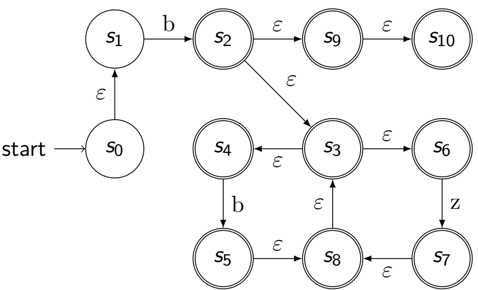


- Teilmengen: $0' = \{0, 1\}$, $1' = \{2, 3, 4, 6, 9, 10\}$, $2' = \{5, 8, 9, 10, 3, 4, 6\}$, $3' = \{7, 8, 9, 10, 3, 4, 6\}$
  Anmerkung: Alter Zustand kann in mehreren neuen vorkommen (z.B. 3)
- Übergänge: $0'b \to 1'$, $1'b \to 2'$, $1'z \to 3'$, $2'b \to 2'$, $2'z \to 3'$, $3'z \to 3'$, $3'b \to 2'$
- Endzustände: $1'$, $2'$, $3'$


KIT Karlsruhe Institute of Technology

# Beispiel: Teilmengenkonstruktion (resultierender Automat)

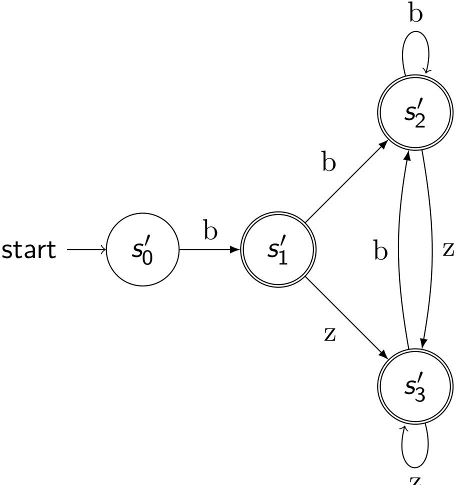


Anmerkung: Dies ist nicht der einfachste mögliche Automat, sondern nur ein deterministischer.

# Äquivalenzklassenbildung

*Äquivalenzklassenbildung macht endl. Automaten minimal*

Initial:

- $\{s_1, \ldots, s_k\} = s'$ und $\{p_1, \ldots, p_l\} = s_E$
- $p_1, \ldots, p_l$ Endzustände, $s_1, \ldots, s_k$ keine Endzustände
- wir betrachten die initialen Äquivalenzklassen $\{s_1, \ldots, s_k\}$ und $\{p_1, \ldots, p_k\}$

Rekursion:

- $s_i \equiv_{k+1} s_j$, wenn $s_i a \rightarrow p_i$, $s_j a \rightarrow p_j$, $s_i$, $s_j$ sowie $p_i$, $p_j$ jeweils in gleicher Klasse nach $k$ Rekursionen, $k = 0, 1, 2, \ldots$ bzw. $s_i a \rightarrow s_i$, $s_j a \rightarrow s_j$ und $s_i$, $s_j$ in gleicher Klasse. Analog wird $p_i \equiv_{k+1} p_j$ definiert

Abschluß:

- Klasseneinteilung ändert sich nach $m$ Schritten nicht mehr, $m < \max(l, k)$
- Äquivalenzklasse je ein Zustand, Übergänge und Endzustände wie bei Teilmengenkonstruktion

# Beispiel: Äquivalenzklassenbildung

Deterministischer Automat (nicht minimal):
$0b \rightarrow 1$, $1b \rightarrow 2$, $1z \rightarrow 3$, $2b \rightarrow 2$, $2z \rightarrow 3$, $3z \rightarrow 3$, $3b \rightarrow 2$

- Zustände $\{0\}$ Endzustände $\{1, 2, 3\}$ Fehler $\{F\}$
- Partitionierung?
  $\{0\}b \rightarrow \{1, 2, 3\}$, $\{0\}z \rightarrow \{F\}$, $\{1, 2, 3\}b \rightarrow \{1, 2, 3\}$,
  $\{1, 2, 3\}z \rightarrow \{1, 2, 3\}$
- Keine weitere Partitionierung

# Beispiel: Äquivalenzklassenbildung (resultierender Automat)

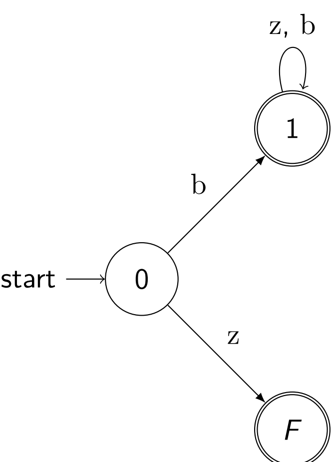

# Aufwand

- Deterministisch machen:
  - exponentiell bei pathologischen Beispielen
  - in der Praxis weniger als quadratisch
- Minimierung:
  - quadratisch
  - Es gibt auch $O(n \log n)$-Algorithmen, praktisch nicht bewährt, Programmlogik kompliziert, die meisten unserer Automaten sind klein, daher nicht notwendig
- Automat unvollständig: minimaler Automat nicht eindeutig, Aufwand NP-vollständig
- Beispiel exponentieller Aufwand der Teilmengenkonstruktion:

$$(a+b)^* a(a+b)^{n-1}$$

Anzahl Zustände des deterministischen Automaten $\geq 2^n$

# End- und Fehlerzustände

- Endzustand entsteht durch die Regel $A \rightarrow a$
- Jeder Fehlerzustand ist Endzustand
- Bei Minimierung müssen die End- und Fehlerzustände erhalten bleiben
  - Äquivalenzklassenbildung beginnt mit $n + 2$ Klassen
    - Anzahl der Endzustände: $n$
    - Ein Fehlerzustand
    - Eine Klasse aller anderen Zustände
- Beachte: Eigentlich sind alle Automaten auf den Folien und in Übersetzerbaubüchern falsch, wenn der Fehlerzustand nicht enthalten ist. Dies ist aber Konvention.

# Kapitel 2: Lexikalische Analyse

1. Eingliederung in den Übersetzer / Zielvorgaben
2. Theoretische Grundlage: Endliche Automaten
3. Implementierung
   - Implementierung endlicher Automaten, Tabellenkompression
   - Der Tokenstrom
   - Implementierung der Stringtabelle
4. Einsatz von Generatoren
   - Flex

# Tabellendarstellung endlicher Automaten

Ziel: Effiziente Ausführung eines endlichen Automaten

- Ermitteln von Übergängen in $O(1)$

Alternativen

- Adjazenzliste: $O(\log(k))$, $k$ maximaler Ausgangsgrad
- Adjazenzmatrix: $O(1)$ mit kleiner Konstante
- Ausprogrammieren (mit Fallunterscheidung): $O(1)$, aber keine Sprungvorhersage möglich

Größe der Adjazenzmatrix $= |S| * |\Sigma|$

- Für klassische Alphabete ist $|\Sigma| = 256$. $\sim 40$ echte Zeichen, alle andern führen in den Fehlerzustand
- $|S| \sim 100$
- Problem Speicherbedarf

# Beispiel für Tabelle

Tabelle:

| Zustand | *b* | *z* | *Trennzeichen* |
|---|---|---|---|
| 0 | 1 | *fehler* | 0 |
| 1 | 1 | 1 | *Ende* |

```
int state = 0;
char cur;

while (!isFinal(state)
   && !isError(state))
{
    cur = next_char();
    state = table[state, cur];
}
if (isError(state))
    return ERROR;

return find_or_insert(text());
```

Achtung: Wir haben hier nur einen Endzustand.

# Beispiel für Programm

```
int state = 0; char cur;
while (true) {
    cur = next_char();
    switch(state) {
    case 0:
        switch(cur) {
            case b: state = 1; break;
            case z: return ERROR;
            case Trennzeichen: state = 0; break;
        } break;
    case 1:
        switch(cur) {
            case b, z: state = 1; break;
            case Trennzeichen: return find_or_insert(text());
        } break;
    }
}
```

# Tabelle vs. Programm: Bewertung

- Pragmatisch: Generatoren können Tabellen besser verwenden
- Programmierte Version schneller und kleiner
- Tabelle übersichtlicher, systematischer, änderungsfreundlicher, aber langsamer
  **Begründung**: Tabelle ist implementiert durch Schleife mit Abfrage nach allen Eventualitäten, führt zu nicht vermeidbaren Leerprozeduren
- Erfahrung: Programmcode in beiden Fällen ähnlich groß, Tabelle kommt extra dazu

# Tabellenkomprimierung

- partitioniere $\Sigma$ in Äquivalenzklassen von Zeichen die stets im gleichen Kontext benutzt werden.
- lege „ähnliche" Spalten zusammen: Benutze „neue" Zeichen $J$ für Übergänge im endlichen Automaten
- Optimiere nach deterministisch Machen und Minimieren
- erfordert zusätzliche Indirektion zur Laufzeit
- Kompression reduziert Tabelle auf 5 bis 10% der ursprünglichen Größe
- Synergetische Effekte durch Prozessorcache

# Besonderheiten

Pragma: Kommentar zur Steuerung der Übersetzung kann eigene, nicht reguläre Syntax enthalten. Behandlung nicht allein durch lexikalische Analyse möglich.
Vorgehen bei Pragmas:

- Pragmatext als Eintrag in Stringtabelle
- Sonderbehandlung (Entschlüsselung während lexikalischer Analyse oder danach?)
- abhängig von Implementierung der Tokens

schwieriges Problem, hier nicht weiter behandelt

# Entschlüsseln von Unicode

- Internationaler Standard zur Codierung von Schriftzeichen
- Grundlage vieler Sprachen wie XML, Java usw.

Probleme:

- $|\Sigma| = 2^{21} - 1$, damit lange Generatorlaufzeiten (deterministisch machen und minimieren) und extrem große Tabellen.
- Gebräuchliche Codierungen wie UTF-8 (C und Systemsoftware) und UTF-16 (Java) haben variable Zeichenlängen.

Lösung:

- Partitioniere $\Sigma$ vorher
- Grundidee:
  reguläre Ausdrücke $(X + Y)$, $(XY)$, $(X)^*$ mit Zeichenmengen $X, Y \subseteq \Sigma$

Beobachtung: Bedeutungstragend weiterhin nur ca. 40 Zeichenmengen

# Vorgehen

Jede Zeichenmenge $Z$ zerlegt $\Sigma$ in $Z$ und $\Sigma \setminus Z$. Für eine Menge $M$ von Zeichenmengen $Z$ bestimme die induzierte Partition von $\Sigma$.

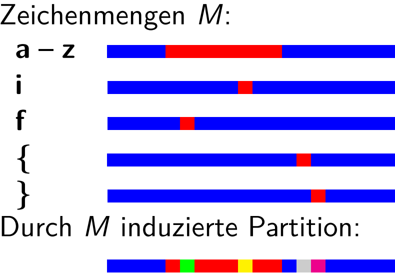


## Algorithmus:

- Stelle jedes $Z$ als Intervall $[b, e)$ dar
- sortiere nach Anfangswert $b$
- Arbeite sortierte Liste ab und erstelle Partitionierung
- Ersetze Zeichenmengen durch Partitionsnummern $J$
- Erzeuge und benutze den Automaten wie bekannt (mit Abbildung $M \to J$)

# Tokenstrom

- tokenstrom = Strom(Token)
- Token = (Key, Value, Position)
- Key:
  - das syntaktische Terminalsymbol des Parsers, definiert durch den Endzustand der lexikalischen Analyse oder vordefiniert für reservierte Bezeichner, z.B. Wortsymbole
- Value:
  - Für Bezeichner und Konstanten: Verweis auf den Eintrag in die Stringtabelle, mit dem man zumindest Text und Textlänge erhalten kann.
  - sonst: null (Key überflüssig, nicht definiert)

# Umfang der Tokens

- Tokenstrom muss nicht tatsächlich als Datenstruktur vorliegen
- Key: Maschinenwortbreite (oft 32 bit)
- Value: Maschinenwortbreite (oft 32 bit)
- Position der Tokens benötigt für Fehlerausgabe
  - Datei, Zeilen- und Spalteninformation (alternativ Zeile und Relativadresse oder nur Relativadresse)
  - 32 bit für Zeile (oder Relativadresse)
  - mind. 16 bit für Spalte
  - Positionierung bei WYSIWYG Editoren, wenn Tabulatoren beliebig definiert werden können?
  - Achtung: Zeilenzählung bei generiertem Code problematisch
- Summe: etwa 12-16 Bytes pro Token

# Tokenstrom: Implementierung

- Anfrage (Funktionsaufruf)
  - Parser ruft Lexer
  - Lexer ruft Parser
- Strom (Pipeline)
- Array (Tokens sind bereits abgelegt)
  - 20% schneller auf heutigen Architekturen wegen Cache
  - das kann sich ändern

# Stringtabelle: Ziele und Kriterien

Ziele:

- Die Merkmale bzw. Schlüssel aller Symbole festlegen, die nicht durch Endzustände des Automaten bestimmt sind.
- Bezeichner und Konstanten durch Merkmal einheitlicher Länge codieren.
- Aufbewahrung der Bezeichner- und Konstantentexte für die weitere Bearbeitung und für Fehlermeldungen.
- Ankerpunkt, von dem aus verschiedene Vereinbarungen eines Bezeichners erreichbar sind (für semantische Analyse).

Kriterien:

- Anfangs unbekannte Anzahl von Bezeichnern und Konstanten unbeschränkter (!) Länge aufnehmen (Faustregel: pro 10 Zeilen 1 Bezeichner).
- Suche nach Bezeichnertexten wenn möglich mit Aufwand $O(1)$.

Hinweis: Für die lexikalische Analyse wird in der Regel eine Stringtabelle nicht unbedingt benötigt, sie dient als „Gedächtnis".

# ADT Stringtabelle

Gelieferte Operationen:

- `insert(text, key)`
- `find_or_insert(text) : (key,value)`
- `get_text(key) : text`

Benötigte Operationen:

*keine*

`insert` dient für Voreinträge (z.B. while)

# Suchverfahren in Stringtabelle

- Sequentielle Suche (nie sinnvoll)
- Suchbaum (in Fortran 77 nötig)
- Hashen
  - Perfektes Hashen (nur bei vorher bekannter Bezeichnermenge)
  - Verkettetes Hashen (Aufwand?)
  - Hashen mit quadratischem Sondieren o.ä. (Aufwand?)

    $$\text{index}_i := (h(x) + i^2 \times g(x)) \mod |\text{Tabelle}|$$

    $i$: i-te Kollision, $h$: Hashfunktion, $g$: optionale Hashfunktion (ggf. $g := 1$)
  - Einträge: Verweise auf Symbole, gleichzeitig deren Merkmal

Achtung: Bestimmte Implementierung der Stringtabelle kann von der Quellsprache erzwungen werden, siehe Fortran

# Umstiegspunkt für Stringtabelle

## Alternativen:

- Perfektes Hashen: bestes Verfahren wenn anwendbar
- Sondieren (z.B. quadratisch):
  Aufwand: Hashfunktion + # Kollisionen
- verkettetes Hashen: Aufwand: Hashfunktion + Kettenlänge
- Suchbaum: Aufwand Pfadlänge im Baum ($O(\log(|\text{Einträge}|))$)
  in formatiertem FORTRAN sind Leerzeichen erlaubt,
  ständiges Berechnen von Hashschlüsseln und Suchen in
  Tabelle ist zu teuer, im Baum ist binäre Suche möglich

## Wann welche Technik?

- perfektes Hashen, wenn möglich
- quadratisches Sondieren mit Aufwand $O(1)$, wenn
  Hashfunktion gleichverteilt und Hashtabelle nur halbvoll;
  Abhilfe Tabellenverdopplung
- verkettetes Hashen: $O(1)$, wenn Hashfunktion ungefähr
  gleichverteilt, keine Abhilfe, wenn letzteres nicht erfüllt ist
- Suchbaum: sonst

# Organisation der Stringtabelle

*Stringtabelle*

Verkettung

Hash-tabelle

| next |
|---|
| index: 0 |
| length: 5 |
| key: BEGIN |
| definition |

| next |
|---|
| index: 7 |
| length: 9 |
| key: ID |
| definition |

*Texttabelle*

`beginifvariable1`

# ADT Stringtabelleneintrag

```
abstract class StringTableEntry is
  next:        StringTableEntry;  // Verkettung
  index:       Integer;           // Index in Texttabelle
  length:      Integer;           // Länge in Texttabelle
  key:         Key;               // Art des Eintrags
  definition : SymbolTableEntry;  // Momentan gültige Definition
end StringTableEntry;
```

Verweise auf Objekte dieses Typs als Merkmal für Bezeichner usw.

# Hashen

- Tabellenlänge: Abstand zu $n \times 256$!
  - Primzahl
  - $2^p$ (Vermeiden von ganzzahliger Division), $p$ kein Vielfaches von 8!
- Hashverfahren:
  - Hashen mit quadratischem Sondieren, ...
    - verlangt eventuell Tabellenverlängerung
  - verkettetes Hashen
- Faustregel: ca. ein Neueintrag für 10 Zeilen Quelltext
- Hashtabelle nach Ende der lexikalischen Analyse überflüssig, nur Symboleinträge und Texttabelle werden noch benötigt

# Hashfunktionen

- Hashfunktion muss schnell berechnet werden können!
- Anfang/Ende vieler Bezeichner gleich (`a1`, `a2`, ...)
- $\mathrm{id} = \mathrm{id}_1 \mathrm{id}_2 \ldots \mathrm{id}_k$
  - $h(\mathrm{id}) = \mathsf{abs}(\mathrm{id}_1) + \mathsf{abs}(\mathrm{id}_k) + \mathsf{abs}(\mathrm{id}_{(k+1)/2})$
  - $h(\mathrm{id}) = c_1 \times \mathsf{abs}(\mathrm{id}_1) + c_2 \times \mathsf{abs}(\mathrm{id}_k) + c_3 \times \mathsf{abs}(\mathrm{id}_{(k+1)/2})$
    - $c_i = 1, 4, 8$? Spreizung über $0 \ldots 255$, abhängig vom Zeichensatz
  - $h(\mathrm{id}) = \Sigma_{i=1}^{k} c_i \times \mathsf{abs}(id_i)$
  - ...
  - alle Berechnungen modulo Tabellenlänge
- bei Hashfunktionen kommt es auf Gleichverteilung an, nicht auf die aktuelle Rechenmethode
  - z.B. spart wortweises Addieren Zeit (verletzt aber die Typregeln)

# Kosten einer Tabellenverdopplung

Sei

$$n = 2^k$$

Zugriffszeit für $n$ Elemente:

$n + n/2 + n/4 + n/8 + \ldots < 2n \in O(n)$

amortisiert für ein Element: $O(1)$

| 1 |
|---|

| 1 | 2 |
|---|---|

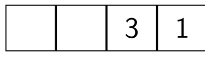


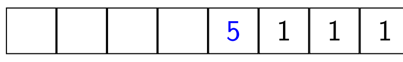


Betrachte Knoten 5: 4 Schreibzugriffe für Kopieren + eigentlicher Schreibzugriff

Achtung: Der Index kann nicht das Merkmal eines Symbols sein, da er sich offenbar ändern kann.

# Kapitel 2: Lexikalische Analyse


1. Eingliederung in den Übersetzer / Zielvorgaben

2. Theoretische Grundlage: Endliche Automaten

3. Implementierung
   - Implementierung endlicher Automaten, Tabellenkompression
   - Der Tokenstrom
   - Implementierung der Stringtabelle

4. Einsatz von Generatoren
   - Flex

# Generatoren für die lexikalische Analyse

- Scannergeneratoren werden eingesetzt um die lexikalische Analyse eines Compilers möglichst kompakt und einfach zu spezifizieren (eine Domain Specific Language).
- Eingabe: Ein Zeichenstrom (ASCII, UTF-8, ...)
- Ausgabe lässt sich meist in der Beschreibungssprache spezifizieren. Mehrere Möglichkeiten zur Anbindung eines Parsers:
  - Push-Schnittstelle: Bei erkanntem Token wird eine Methode des Parsers aufgerufen
  - Pull-Schnittstelle: Der Parser ruft eine Methode im Lexer auf um das nächste Token zu bekommen. Meist am einfachsten zu programmieren.
  - Pufferung: Tokenstrom wird vor Syntaxanalyse teilweise oder komplett vorberechnet. Dies kann günstiger für den Cache sein.
- Typischerweise keine automatische Unterstützung für Stringtabellen (da oft sehr sprachspezifisch) und Fehlerbehandlung.

# Verbreitete Generatoren

- *Lex*: Werkzeug zur Generierung von Scannern bekannt aus dem Unix-/C-Umfeld. Spezifikation von regulären Ausdrücken erzeugt Tabellengesteuerten Scanner.
- Flex ist eine Open-Source Implementierung von Lex.
- Zahlreiche Portierungen auf andere Programmiersprachen. Beispiele: *JLex* (Java), *CsLex* (C#), *Alex* (Haskell), ...
- Es gibt auch Scanner die nicht mit regulären Ausdrücken/endlichen Automaten arbeiten. Ein bekannter Vertreter ist *antlr* der $\mathrm{LL}(k)$ Grammatiken benutzt.

# Vor- und Nachteile von Generatoren

Vorteile:

- Die Spezifikation von Scannern ist kompakt
  $\rightarrow$ verständlich und gut wartbarer Code, weniger Fehler
- Automatische Konsistenzprüfung
- Kurze Entwicklungszyklen, schnelles Prototyping möglich
- Scannergeneratoren erzeugen sehr performanten Code.

Nachteile:

- Neue Sprache/Werkzeug muss erlernt werden
- Integration in Buildsystem notwendig
- Fehlersuche oft sehr mühsam da generierter Code für Menschen schlecht lesbar
- Fehlende Flexibilität; In der Praxis gibt es häufig kleinere Ausnahmen die man nur umständlich oder gar nicht mit Generatoren umsetzen kann.

# Scanner für XML

XML-Dateien lassen sich in Tokens zerlegen. Beispiel:

```
<?xml version='1.0'?>
<!-- my personal books -->
<books>
    <book name='Goedel, Escher, Bach'/>
</books>
```

: Strings
: XML-Namen
: weitere Tokens

# Scanner für XML

XML-Dateien lassen sich in Tokens zerlegen. Beispiel:

```
<?xml version='1.0'?>
<!-- my personal books -->
<books>
    <book name='Goedel, Escher, Bach'/>
</books>
```

: Strings
: XML-Namen
: weitere Tokens

# Reguläre Ausdrücke

Spezifikation Regulärer Ausdrücke in Flex (Auszug):

| | |
|---|---|
| `x` | Zeichen 'x' erkennen |
| `"xy"` | Zeichenkette xy erkennen (ohne Interpretation) |
| `\x` | Zeichen 'x' erkennen (ohne Interpretation) |
| `.` | Jedes Zeichen außer Zeilenumbruch erkennen |
| `[xyz]` | Zeichen 'x', 'y' oder 'z' erkennen |
| `[abj-oZ]` | Zeichen 'a', 'b', 'Z' oder Zeichen von 'j' bis 'o' erkennen |
| `[^A-Z]` | Alle Zeichen außer den Zeichen von 'A' bis 'Z' erkennen |
| `x\|y` | *x* oder *y* erkennen |
| `(x)` | *x* erkennen (verändert die Bindung) |
| `x*` | 0, 1 oder mehrere Vorkommen von *x* erkennen |
| `x+` | 1 oder mehrere Vorkommen von *x* erkennen |
| `x?` | 0 oder 1 Vorkommen von *x* erkennen |
| `{Name}` | Expansion der Definition *Name* |
| `\t,\n,\r` | Tabulator, Zeilenumbruch, Wagenrücklauf erkennen |

# Spezifikation

```
NameStartChar [a-zA-Z]
NameChar {NameStartChar}|[\-\.0-9]
Name {NameStartChar}({NameChar})*
Comment "<!--"([^\-]|"-"[^\-])*"-->"
String \'[^\']*\'|\"[^\"]*\"
Token "<?"|"</"|"<"|"/>"|">"|"?>"|"="

%%
{String} printf("String: %s\n", yytext);
{Name} printf("Name: %s\n", yytext);
{Comment} /* skip */
{Token} printf("Token: %s\n", yytext);
.|\n /* skip */

%%
int main(void) {
  yylex();
  return 0;
}
```

# Spezifikation

```
NameStartChar [a-zA-Z]
NameChar {NameStartChar}|[\-\.0-9]
Name {NameStartChar}({NameChar})*
Comment "<!--"([^\-]|"-"[^\-])*"-->"
String \'[^\']*\'|\"[^\"]*\"
Token "<?"|"</"|"<"|"/>"|">"|"?>"|"="


%%
{String} printf("String: %s\n", yytext);
{Name} printf("Name: %s\n", yytext);
{Comment} /* skip */
{Token} printf("Token: %s\n", yytext);
.|\n /* skip */

%%
int main(void) {
  yylex();
  return 0;
}
```

# Verwendung von Flex

```
$ flex -o scanner.c scanner.l
$ gcc scanner.c -lfl -o scanner
$ ./scanner < test.xml
Token: <?
Name: xml
Name: version
Token: =
String: "1.0"
Token: ?>
Token: <
Name: books
Token: >
Token: <
Name: book
Name: name
Token: =
String: 'Goedel, Escher, Bach'
Token: />
Token: </
Name: books
Token: >
```

test.xml:

```
<?xml version="1.0"?>
<!-- my personal books -->
<books>
  <book name=
    'Goedel, Escher, Bach'/>
</books>
```