3. Bäume aufbauen - Überblick

Notation und Struktur der Eingabe prüfen und als Baum repräsentieren

Aufgaben

Eingabeverarbeitung
Scanning
Symbol-Codierung
Konvertierung

Parsing
Baumaufbau

Module

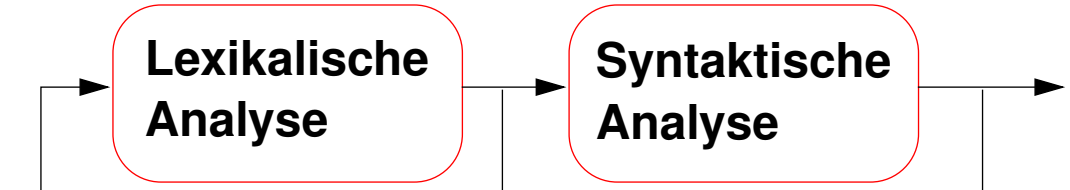

Schnittstellen: Repräsentation der Eingabe

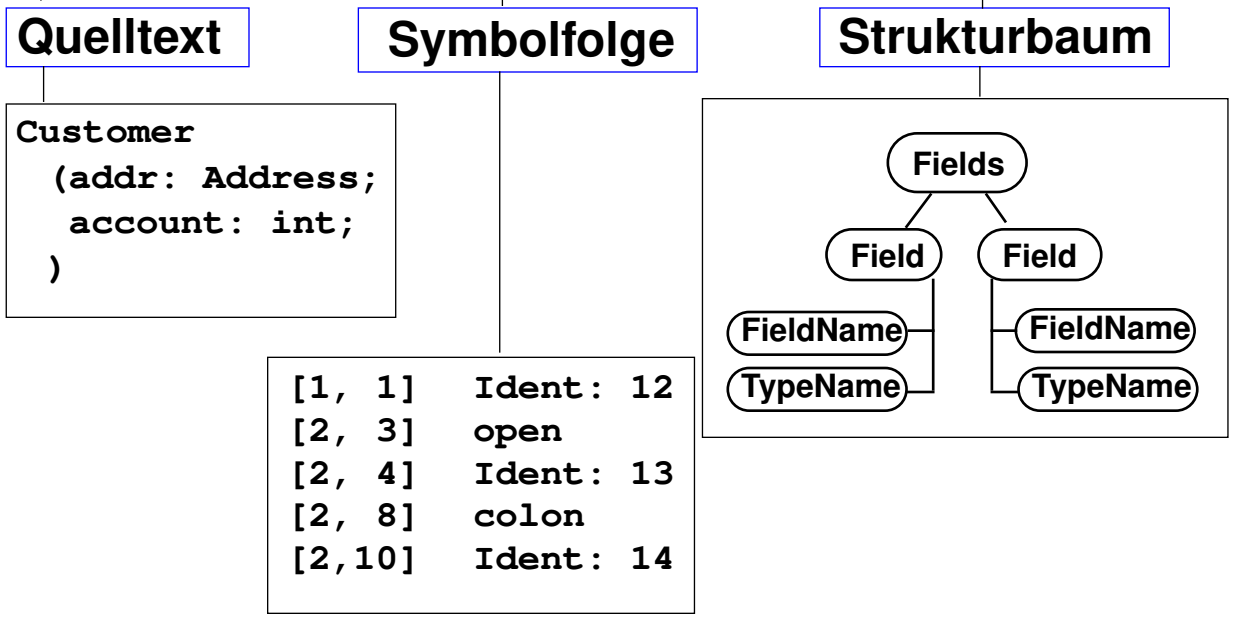

© 2002 bei Prof. Dr. Uwe Kastens

Eli: Spezifikation und Generierung des Baumaufbaus

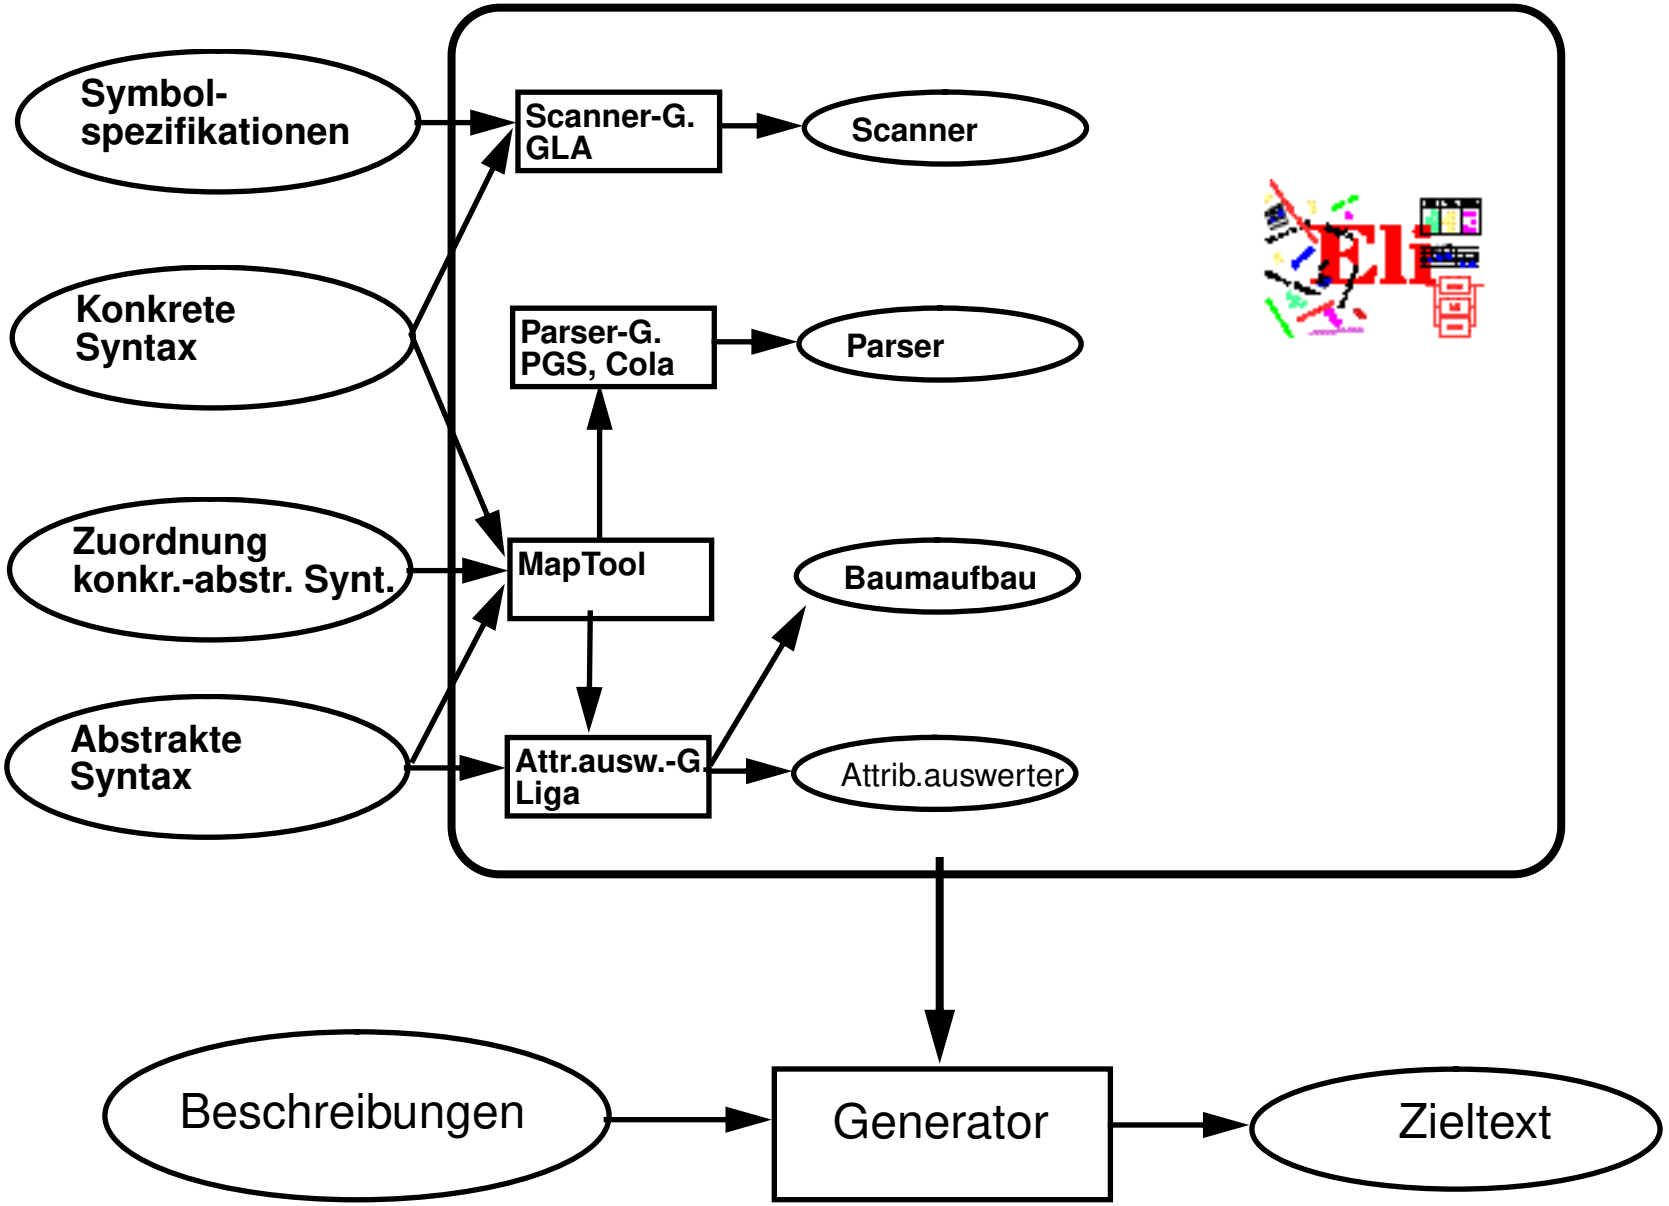

© 2002 bei Prof. Dr. Uwe Kastens

Spezifikationen am Beispiel des Wrapper-Generators

Notation der Grundsymbole
.gla

```
Identifier:   C_IDENTIFIER
String:       C_STRING_LIT
              C_COMMENT
```

Struktur der Eingabe
.con

```
Specification:  Sequence.
Sequence:       Sequence Element / .
Element:        TypeName ';'.
Element:        FileName.
TypeName:       Identifier.
FileName:       String.
```

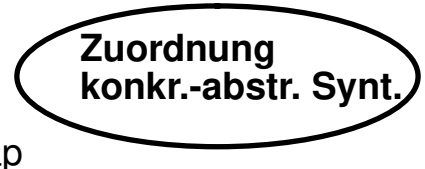

.map

leer -
konkrete und abstrakte Syntax sind gleich

Struktur der Bäume
.lido

```
RULE: Specification LISTOF Element
COMPUTE ...

SYMBOL FileName COMPUTE ...
SYMBOL TypeName COMPUTE ...
```

nur die Symbole und Produktionen, die
Berechnungen haben

© 2002 bei Prof. Dr. Uwe Kastens

Strukturierung am Beispiel Terminliste

Neues Beispiel für die Spezifikationen der Strukturierung bis zum Baumaufbau:

Eingabesprache: Listen von Terminangaben:

```
1.11.       20:00      "Theaterbesuch"
Do          14:15      "GSS Vorlesung"
werktags    12:05      "Essen im Palmengarten"
Mo, Do      8:00       "Dekanat"
31.12.      23:59      "Jahresende"
12/31       23:59      "End of year"
```

© 2002 bei Prof. Dr. Uwe Kastens

Konkrete Syntax

spezifiziert die **Struktur der Eingabe** durch eine kontext-freie Grammatik:

```
Termine:      Eintrag+ .
Eintrag:      Tag Zeit Beschreibung .
Tag:          Datum / Muster .
Datum:        TagNum '.' MonNum '.' /
              MonNum '/' TagNum .
TagNum:       Integer .
MonNum:       Integer .
Muster:       Muster ',' WochenTag /
              WochenTag /
              TagesGruppe .
WochenTag:    TagesName .
TagesGruppe:  'werktags' .
Zeit:         Zeitpunkt .
Zeitpunkt:    Uhrzeit .
```

Notation:

- Folge von Produktionen
- literale Terminale in '
- EBNF-Konstrukte:
  - / Alternative
  - ( ) Klammern
  - [ ] Option
  - +, * Wiederholung
  - // Wiederholung mit Trenner

  Bedeutung siehe GdP

Beispiel:

```
Do          14:15     "GSS Vorlesung"
werktags    12:05     "Essen im Palmengarten"
Mo, Do      8:00      "Dekanat"
31.12.      23:59     "Jahresende"
12/31       23:59     "End of year"
```

© 2002 bei Prof. Dr. Uwe Kastens

Abstrakte Syntax

spezifiziert die **Strukturbäume** durch eine kontext-freie Grammatik:

```
RULE pTermine:      Termine   LISTOF Eintrag                END;
RULE pZeitEintrag:  Eintrag   ::= Tag Zeit Beschreibung    END;

RULE pDatum:        Tag       ::= Datum                    END;
RULE pMuster:       Tag       ::= Muster                   END;

RULE pDatumZahlen:  Datum     ::= TagNum MonNum            END;
RULE pTag:          TagNum    ::= Integer                  END;
RULE pMonat:        MonNum    ::= Integer                  END;

RULE pMusterListe:  Muster    LISTOF Element               END;
RULE pTagesName:    Element   ::= TagesName                END;
RULE pWerktage:     Element   ::= 'werktags'               END;

RULE pZeitpunkt:    Zeit      ::= Zeitpunkt                END;
RULE pUhrzeit:      Zeitpunkt ::= Uhrzeit                  END;
```

Notation:

- Sprache Lido für Berechnungen in Strukturbäumen
- optional benannte Produktionen,
- kein EBNF außer LISTOF (evtl. leere Folge)

© 2002 bei Prof. Dr. Uwe Kastens

Beispiel eines Strukturbaumes

- Produktionsnamen als Knotentypen
- Werte der Terminale an den Blättern

Ausgabe automatisch erzeugt durch Eli‘s Unparser-Generator

```
pZeitEintrag(
   pDatum(pDatumZahlen(pTag(1),pMonat(11))),
   pZeitpunkt(pUhrzeit(1200)),"Theaterbesuch"),
pZeitEintrag(
   pMuster(pTagesName(4)),
   pZeitpunkt(pUhrzeit(855)),"GSS Vorlesung"),
pZeitEintrag(
   pMuster(pWerktage()),
   pZeitpunkt(pUhrzeit(725)),"Essen im Palmengarten"),
pZeitEintrag(
   pMuster(pTagesName(1),pTagesName(4)),
   pZeitpunkt(pUhrzeit(480)),"Dekanat"),
pZeitEintrag(
   pDatum(pDatumZahlen(pTag(31),pMonat(12))),
   pZeitpunkt(pUhrzeit(1439)),"Jahresende"),
pZeitEintrag(
   pDatum(pDatumZahlen(pTag(31),pMonat(12))),
   pZeitpunkt(pUhrzeit(1439)),"End of year")
```

© 2002 bei Prof. Dr. Uwe Kastens

Strukturbaumausschnitt graphisch

- Produktionsnamen als Knotentypen
- Werte der Terminale an den Blättern

Ausgabe automatisch erzeugt durch Eli's Unparser-Generator, Baumstruktur durch Klammerung

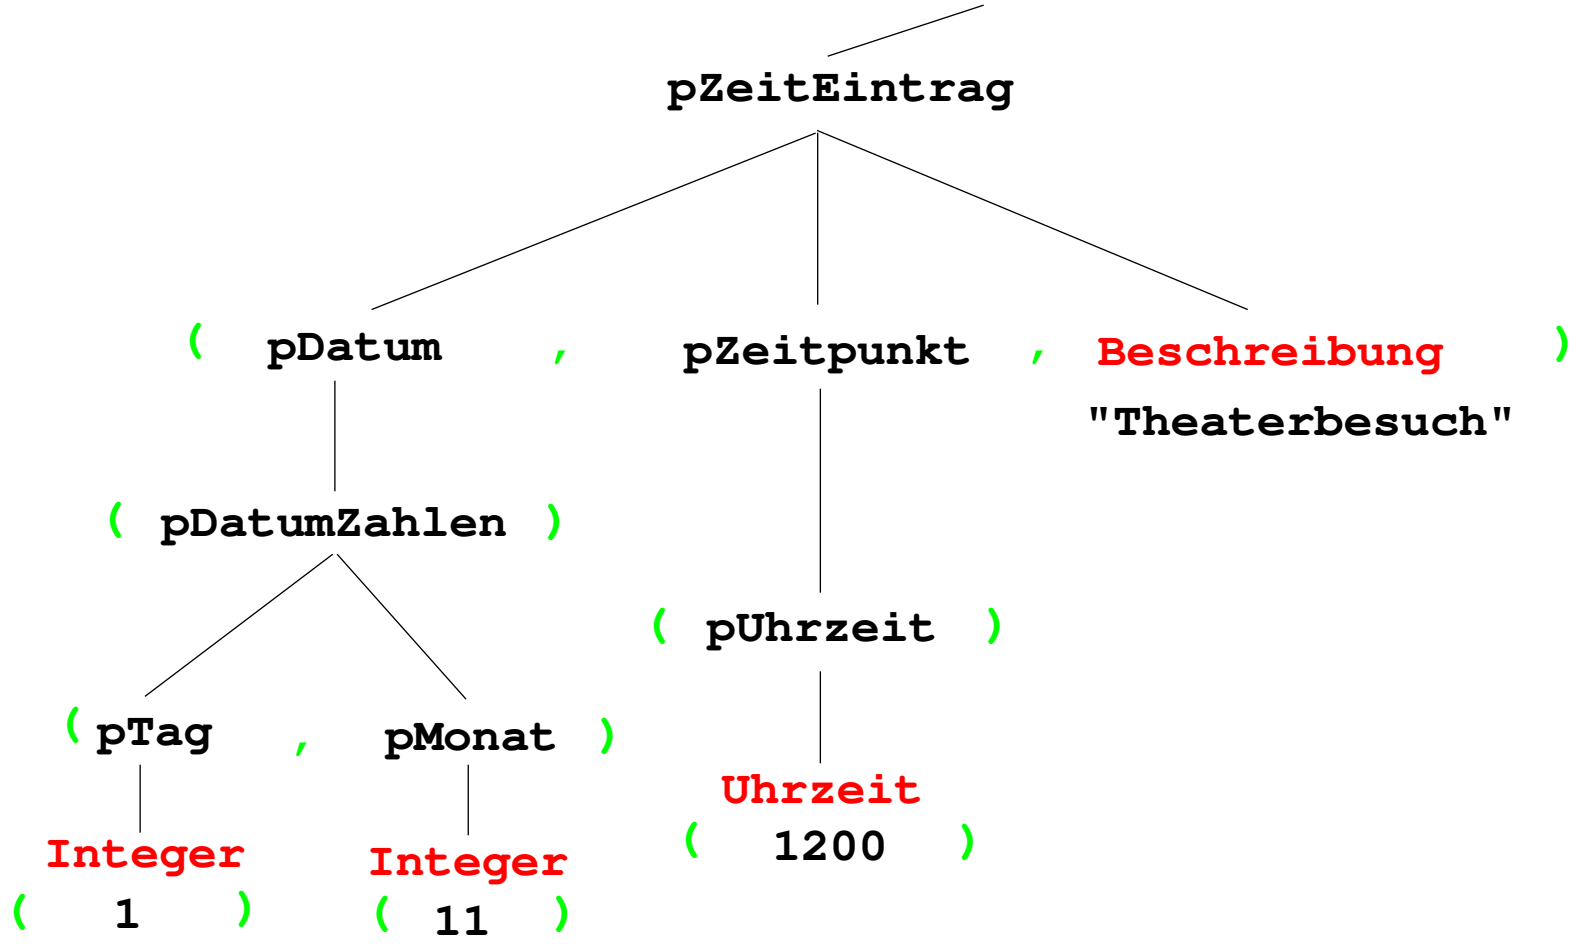

© 2002 bei Prof. Dr. Uwe Kastens

Symbolabbildung: konkrete - abstrakte Syntax

konkrete Syntax:

```
Muster:       Muster ',' WochenTag /
              WochenTag /
              TagesGruppe .
WochenTag:    TagesName .
TagesGruppe:  'werktags' .
```

Vereinfachung der abstrakten Syntax

Menge von Nichtterminalen der konkreten Syntax ->

ein Nichtterminal der abstrakten Syntax

Abbildung:

```
MAPSYM
Element ::= TagesGruppe WochenTag.
```

Element steht in der abstrakten Syntax für die angegebenen Nichtterminale

abstrakte Syntax:

```
RULE pMusterListe:  Muster    LISTOF Element          END;
RULE pTagesName:    Element   ::= TagesName           END;
RULE pWerktage:     Element   ::= 'werktags'          END;
```

© 2002 bei Prof. Dr. Uwe Kastens

Regelabbildung

konkrete Syntax:

```
Datum:          TagNum '.' MonNum '.' /
                MonNum '/' TagNum .
```

Abbildung:

```
MAPRULE
Datum: TagNum '.' MonNum '.' < $1 $2 >.
Datum: MonNum '/' TagNum     < $2 $1 >.
```

unterschiedliche Produktionen der konkreten Syntax

werden in der abstrakten Syntax **vereinheitlicht**

abstrakte Syntax:

```
RULE pDatumZahlen:    Datum ::= TagNum MonNum END;
```

© 2002 bei Prof. Dr. Uwe Kastens

Literale und nicht-literale Terminale

Definition der Notation von

- literalen Terminalen (unbenannt): **in der konkreten Syntax**
- nicht-literalen Terminalen (benannt): in zusätzlicher **Spezifikation für den Scanner-Generator**

```
Termine:      Eintrag+ .
Eintrag:      Tag Zeit Beschreibung .
Tag:          Datum / Muster .
Datum:        TagNum '.' MonNum '.' /
              MonNum '/' TagNum .
TagNum:       Integer .
MonNum:       Integer .
Muster:       Muster ',' WochenTag /
              WochenTag /
              TagesGruppe .
WochenTag:    TagesName .
TagesGruppe:  'werktags' .
Zeit:         Zeitpunkt .
Zeitpunkt:    Uhrzeit .
```

© 2002 bei Prof. Dr. Uwe Kastens

Spezifikation nicht-literaler Terminale

Der Generator GLA generiert einen Scanner aus

- Notation der literalen Terminale
  von Eli aus der konkreten Syntax extrahiert
- Spezifikation der nicht-literalen Terminale
  in Dateien vom Typ **`.gla`**

Form der Spezifikationen:

```
Name:          $  regulärer Ausdruck                      [CodierFunktion]

TagesName:     $  Mo|Di|Mi|Do|Fr|Sa|So                    [mktag]

Uhrzeit:       $(([0-9]|1[0-9]|2[0-3]):[0-5][0-9])        [mkuhrzeit]
```

Vorgefertigte Spezifikationen:

```
Beschreibung:  C_STRING_LIT
Integer:       PASCAL_INTEGER
```

© 2002 bei Prof. Dr. Uwe Kastens

Scanner-Spezifikation: Reguläre Ausdrücke

Notation	Zeichenfolgen, die akzeptiert werden
`c`	das Zeichen c; außer Zeichen mit spezieller Bedeutung, siehe c
`\c`	Zwischenraum, Tab, Zeilenwechsel, `\".[]^()|?+*{}/$<`
`"s"`	die Zeichenfolge s
`.`	jedes einzelne Zeichen außer Zeilenwechsel
`[xyz]`	genau ein Zeichen aus der Menge {x, y, z}
`[^xyz]`	genau ein Zeichen, das nicht aus der Menge {x, y, z} ist
`[c-d]`	genau ein Zeichen, dessen ASCII-Code zwischen c und d einschließlich liegt
`(e)`	durch e spezifizierte Zeichenfolge
`ef`	durch e spezifizierte Zeichenfolge gefolgt von einer durch f spezifizierten
`e | f`	durch e oder durch f spezifizierte Zeichenfolge
`e?`	leere oder durch e spezifizierte Zeichenfolge
`e+`	ein oder mehrere Auftreten von Zeichenfolgen, die durch e spezifiziert sind
`e*`	leere oder durch e+ spezifizierte Zeichenfolge
`e {m,n}`	mindestens m und höchstens n Zeichenfolgen, die durch e spezifiziert sind

e und f sind reguläre Ausdrücke, wie sie hier definiert sind.

Jeder reguläre Ausdruck **akzeptiert die längste Zeichenfolge**, die seiner Definition genügt.

Auflösung von **Mehrdeutigkeiten**:
1. die **längere akzeptierte Zeichenfolge**
2. bei gleicher Länge: die **früher angegebene Regel**

© 2002 bei Prof. Dr. Uwe Kastens

Scanner-Spezifikation: Programmierte Scanner

Das Akzeptieren bestimmter Zeichenfolgen kann durch eine Funktion implementiert werden. Damit kann man Zeichenfolgen operational spezifizieren, die durch reguläre Ausdrücke nicht oder schwierig beschreibbar sind.

Der Anfang der Zeichenfolge wird durch einen regulären Ausdruck spezifiziert, es folgt der geklammerte Name der Funktion. z. B. für Zeilenkommentare wie in Ada

```
$-- (auxEOL)
```

Parameter der Funktion: ein Pointer auf das erste Zeichen der bisher akzeptiertenFolge, und ihre Länge. Ergebnis: Pointer auf das erste Zeichen nach der gesamten Folge:

```
char *Name(char *start, int length)
```

Einige verfügbare programmierte Scanner und was sie akzeptieren:

auxEOL	alle Zeichen bis zum nächsten Zeilenwechsel einschließlich
auxCString	ein C-String-Literal nach dem einleitenden "
auxM3Comment	Modula-3-Kommentar nach dem einleitenden (*, mit (* und *) geklammert, auch geschachtelt
Ctext	C-Verbundanweisungen nach dem einleitenden { mit { und } geklammert, auch geschachtelt

© 2002 bei Prof. Dr. Uwe Kastens

Scanner-Spezifikation: Codier-Funktionen

Die **akzeptierte Zeichenfolge** wird an eine Codier-Funktion übergeben (**`start`**, **`length`**)

Sie liefert die Codierung des akzeptierten Symbols (**`intrinsic`**)
d. h. eine ganze **Zahl, die seine Identität oder sein Wert repräsentiert.**

Dazu wird ggf. die Zeichenfolge **gespeichert und/oder konvertiert**.

Alle Codier-Funktionen haben dieselbe **Signatur**:

```
void Name (char *start, int length, int *class, int *intrinsic)
```

Die **Symbolklasse** (Terminalsymbol) kann ggf. geändert werden (**`class`**), z. B. um Wortsymbole von Bezeichnern zu unterscheiden.

Verfügbare Codierfunktionen:

`mkidn`	Zeichenfolge in eine Hash-Tabelle eintragen und bijektiv codieren
`mkstr`	Zeichenfolge speichern; jede erhält einen neuen Code
`c_mkstr`	C-String-Literal in seinen Wert konvertieren, speichern und codieren
`mkint`	Ziffernfolge in eine ganze Zahl konvertieren und diesen Wert als Code liefern
`c_mkint`	Literal für ganze Zahlen in C konvertieren und diesen Wert als Code liefern

© 2002 bei Prof. Dr. Uwe Kastens

Scanner-Spezifikation: Vorgefertigte Spezifikationen

Vorgefertigte vollständige Spezifikationen (regulärer Ausdruck, ggf. programmierter Scanner und Codier-Funktion) können **unter ihrem Namen** abgerufen werden:

```
Identifier:  C_IDENTIFIER
```

Für viele Symbole aus Programmiersprachen sind vorgefertigte Spezifikationen verfügbar (vollständige Spezifikation in der Dokumentation):

```
C_IDENTIFIER, C_INTEGER, C_INT_DENOTATION, C_FLOAT,
C_STRING_LIT, C_CHAR_CONSTANT, C_COMMENT

PASCAL_IDENTIFIER, PASCAL_INTEGER, PASCAL_REAL,
PASCAL_STRING, PASCAL_COMMENT

MODULA2_INTEGER, MODULA2_CHARINT, MODULA2_LITERALDQ,
MODULA2_LITERALSQ, MODULA2_COMMENT

MODULA3_COMMENT, ADA_IDENTIFIER, ADA_COMMENT, AWK_COMMENT

SPACES, TAB, NEW_LINE
```

werden nur benutzt, wenn irgendein Symbol mit solch einem Zeichen beginnt, diese Zeichen aber trotzdem Symbole trennen sollen.

Die Codier-Funktionen können auch überschrieben werden.

© 2002 bei Prof. Dr. Uwe Kastens

Generierung der Baumausgabe

Strukturbaum mit Knotentypen und Werten an den terminalen Blättern ausgeben:

```
pZeitEintrag(
   pDatum(pDatumZahlen(pTag(1),pMonat(11))),
   pZeitpunkt(pUhrzeit(1200)),"Theaterbesuch"),
pZeitEintrag(
```

Ausgabe durch Aufrufe von Pattern-Konstruktor-Funktionen in Baumkontexten

Spezifikationen dafür kann der Unparser-Generator automatisch **erzeugen**:

Unparser generiert aus abstrakter Syntax:

```
Abstract.lido:tree
```

Ausgabe an der Grammatik-Wurzel:

```
SYMBOL ROOTCLASS COMPUTE
   BP_Out(THIS.IdemPtg);
END;
```

Ausgabe nicht-literaler Terminale:

```
TagesName:     $ int
Uhrzeit:       $ int
Integer:       $ int
```

Umbenennung einer PTG-Funktion:

```
#define PTGBeschreibung(x)PTGId(x)
```

Benutzung vordefinierter PTG-Pattern:

```
$/Output/PtgCommon.fw
```

© 2002 bei Prof. Dr. Uwe Kastens