

E2. Symbole und Syntax Überblick

E

EWS-3.1

Grundbegriffe zur **formalen Definition von Sprachen**:

- **Alphabet**: Menge von Zeichen
- **Wort**: Folge von Zeichen aus Alphabet - gebildet nach bestimmten Regeln (Ebene 1)
Satz: Folge von Symbolen aus Vokabular - gebildet nach bestimmten Regeln (Ebene 2)
(Wort, Satz), (Zeichen, Symbol) und (Alphabet, Vokabular) paarweise synonym
- **Sprache**: Menge von Worten bzw. Sätzen

Kalküle zur Bildung von Worten und Sätzen:

- **reguläre Ausdrücke**
zur Definition der **Notation von Grundsymbolen**
(Ebene 1 der Spracheigenschaften)

zur Definition von **Textmustern**
angewandt zum Suchen und Ersetzen von Zeichenfolgen
programmiert in PHP, Perl, Unix-sh
- **kontextfreie Grammatik**
zur Definition der **Menge der syntaktisch korrekten Sätze** einer Sprache
(Ebene 2 der Spracheigenschaften)

Struktur der syntaktisch korrekten Sätze einer Sprache

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 301

Ziele:

Zusammenhang der Begriffe erkennen

in der Vorlesung:

- Die Begriffe werden kurz erklärt und
- der Zusammenhang gezeigt.
- Auf der lexikalischen Ebene werden meist die Bezeichnungen Wort, Zeichen, Alphabet benutzt; aus der syntaktischen Ebene spricht man stattdessen von Satz, Symbol, Vokabular - bei gleicher Bedeutung.
- Die Anwendungen der Kalküle werden erklärt.

Alphabete und Zeichenfolgen

E

EWS-3.2

Ein **Alphabet** ist eine nicht-leere **Menge von Zeichen** zur Bildung von Zeichenfolgen.

Wir betrachten hier nur Alphabete mit endlich vielen Zeichen.

Alphabete werden in Formeln häufig mit Σ bezeichnet;
sonst gibt man ihnen individuelle Namen oder benutzt sie unbenannt.

Beispiele:

$\Sigma =$	{T, F}
Dualziffern =	{0, 1}
Dezimalziffern =	{0, 1, 2, 3, 4, 5, 6, 7, 8, 9}
Kleinbuchstaben =	{a, b, ..., z}
Nukleotide =	{A, C, G, U}
ASCII =	standardisierter Zeichensatz mit 128 Zeichen

Ein **Wort über einem Alphabet A** ist eine Folge von Zeichen aus A.

formal: eine Folge $a_1 a_2 \dots a_n$, mit $a_i \in A$, für $i = 1, \dots, n$.

n ist die **Länge der Folge** bzw. die **Länge des Wortes**.

Beispiele: Wort der Länge 7 über dem Alphabet Dualziffern: 1001101

Die **leere Folge** bzw. das **leere Wort** wird mit ϵ (epsilon) bezeichnet.

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 302

Ziele:

Wörter über Alphabeten

in der Vorlesung:

Erläuterungen und Beispiele dazu

Reguläre Ausdrücke

Ein regulärer Ausdruck R

definiert eine **Mengen von Worten** über einem Alphabet A , die **Sprache $L(R)$** .

Ein regulärer Ausdruck kann aus folgenden 8 Formen rekursiv zusammengesetzt sein.
 F und G seien reguläre Ausdrücke.

regulärer Ausdruck R	Sprache $L(R)$	Erklärung
a	$\{a\}$	Zeichen a als Wort
FG	$\{fg \mid f \in L(F), g \in L(G)\}$	Zusammenfügen von 2 Worten
$F \mid G$	$\{f \mid f \in L(F)\} \cup \{g \mid g \in L(G)\}$	Alternativen
ε	$\{\varepsilon\}$	das leere Wort
(F)	$L(F)$	Klammerung
F^+	$\{f_1 f_2 \dots f_n \mid f_i \in L(F), \text{ für } n \geq 1, i=1, \dots, n\}$	nicht-leere Folgen von Worten aus $L(F)$
F^*	$\{\varepsilon\} \cup L(F^+)$	Folgen von Worten aus $L(F)$
F^n	$\{f_1 f_2 \dots f_n \mid f_i \in L(F), \text{ für } i = 1, \dots, n\}$	Folgen von genau n Worten aus $L(F)$

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 303

Ziele:

Definition von regulären Ausdrücken verstehen

in der Vorlesung:

Erläuterungen zu

- rekursiver Definition,
- Hintereinanderschreibung von Zeichen und Teilworten,
- Alternativen,
- leer und Klammern,
- Folgen von Worten

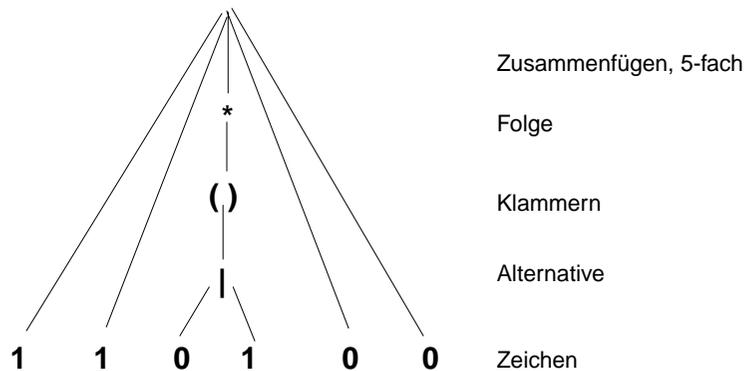
Verständnisfragen:

Unterscheiden Sie:

- das leere Wort,
- die leere Menge,
- die Menge, die nur das leere Wort enthält.

Struktur eines regulären Ausdruckes

1 1 (0 | 1)* 0 0



verbal:

Jedes Wort aus der Sprache dieses regulären Ausdruckes besteht aus zwei 1, gefolgt von beliebig vielen 0 oder 1, gefolgt von zwei 0.

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 304

Ziele:

Aufbau von regulären Ausdrücken verstehen

in der Vorlesung:

Erläuterungen:

- rekursive Konstruktion,
- Struktur erkennen.
- Bedeutung folgt der Struktur.
- Verbale Beschreibung folgt der Struktur.
- Das Alphabet ergibt sich aus den Zeichen, die in dem regulären Ausdruck vorkommen.

Beispiele für reguläre Ausdrücke

Name	regulärer Ausdruck A	Worte aus seiner Sprache L(A)
<i>Abc</i> =	$(a b) (c d \epsilon)$	ac bc ad bd a b
<i>Anrede</i> =	Sehr geehrte(r ϵ) (Frau Herr)	Sehr geehrte Frau
<i>Dig</i> =	$0 1 \dots 9$	7
<i>sLet</i> =	$a b \dots z$	x
<i>cLet</i> =	$A B \dots Z$	B
<i>Let</i> =	<i>sLet</i> <i>cLet</i>	m N
<i>Bezeichner</i> =	<i>Let</i> (<i>Let</i> <i>Dig</i>)*	Maximum min3 a
<i>GeldBetrag</i> =	<i>Dig</i> ⁺ , <i>Dig</i> ²	23,95 0,50
<i>KFZ</i> =	$(cLet cLet^2 cLet^3) - (cLet cLet^2) - (Dig Dig^2 Dig^3 Dig^4)$	PB-AX-123
<i>Dual</i> =	$1^3 (1 0)^* 0^3$	1111000 111000 1111101010000

Wenn **Namen** von regulären Ausdrücken **in regulären Ausdrücken** verwendet werden, müssen sie von den Zeichen unterschieden werden können; hier *Namen* kursiv.

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 305

Ziele:

Reguläre Ausdrücke anwenden lernen

in der Vorlesung:

Einen regulären Ausdruck verstehen:

- Struktur erkennen,
- Bedeutung erkennen, verbal beschreiben,
- Sprache herleiten,
- Beispiele für Worte aus der Sprache geben. Einen regulären Ausdruck entwerfen:
- Beispiele für Worte aus der Sprache geben.
- Sprache herleiten, verbal beschreiben,
- Struktur entwerfen,
- regulären Ausdruck aufschreiben.

Beispiele für Definitionen von Grundsymbolen

<i>Pascal_Identifier</i> =	<i>Let</i> (<i>Let</i> <i>Dig</i>)*
<i>C_Identifier</i> =	(<i>Let</i> $_$) (<i>Let</i> $_$ <i>Dig</i>)*
<i>ADA_Identifier</i> =	<i>Let</i> (($_$ ϵ) (<i>Let</i> <i>Dig</i>))*
<i>PHP_Var_Identifier</i> =	$\$$ (<i>Let</i> $_$) (<i>Let</i> $_$ <i>Dig</i>)*
<i>Pascal_Real</i> =	$((Dig^+ \cdot Dig^+) ((e E) (+ - \epsilon) Dig^+) \epsilon) (Dig^+ (e E) (+ - \epsilon) Dig^+)$
<i>HexDig</i> =	<i>Dig</i> a b c d e f A B C D E F
<i>HTML_CharRef</i> =	$\&$ (<i>Let</i> ⁺ $\#$ <i>Dig</i> ⁺ $\#x$ <i>HexDig</i> ⁺) ;

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 306

Ziele:

Definitionen verstehen

in der Vorlesung:

- Reguläre Ausdrücke untersuchen,
- Beispiele für Worte seiner Sprache angeben

Reguläre Ausdrücke als Textmuster

In Sprachen, die zur **Textverarbeitung** eingesetzt werden, benutzt man **reguläre Ausdrücke, um Textmuster zu definieren**.

Beispiele:

suche alle Dateinamen der Form `ews(0|1|2|3|4|5|6|7|8|9)3.html`

in der Schreibweise von Unix-sh `ls ews[0-9][0-9][0-9].html`

Aufruf einer PHP-Funktion `preg_match ("/[dD]aß/", $absatz)`
sucht ein Textmuster in einer Zeichenreihe Muster Zeichenreihe

```
$d = "[0-9]";
preg_match ("/ews$d$d$d\.html/", $files)
```

Reguläre Ausdrücke als Textmuster sind umfassend in der Skriptsprache Perl definiert und so in PHP übernommen.

Auf den vorigen Folien haben wir die **grundlegenden Begriffe** für reguläre Ausdrücke mit der **dafür üblichen Notation** eingeführt. In **PHP, Perl**, Unix-sh werden die gleichen Begriffe aber in anderer **Notation** verwendet.

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 307

Ziele:

Anwendung von regulären Ausdrücke als Textmuster

in der Vorlesung:

- Beispiele erläutern.
- Neue Notation begründen.

Notation von regulären Ausdrücken in PHP

a	das Zeichen a
<i>F</i> <i>G</i>	Zusammenfügen von 2 Worten
<i>F</i> <i>G</i>	Alternativen
(<i>F</i>)	Klammerung
<i>F</i> ?	Option; wie <i>F</i> ε
<i>F</i> +	nicht-leere Folge von Worten aus L(<i>F</i>)
<i>F</i> *	beliebig lange Folge von Worten aus L(<i>F</i>)
<i>F</i> { <i>m</i> , <i>n</i> }	Folge mit mindestens <i>m</i> und höchstens <i>n</i> von Worten aus L(<i>F</i>)
<i>F</i> { <i>m</i> }	Folge mit genau <i>m</i> Worten aus L(<i>F</i>)
[<i>abc</i>]	alternativ ein Zeichen aus der Klammer
[^ <i>abc</i>]	alternativ ein anderes Zeichen als die in der Klammer
[<i>a-zA-Z</i>]	alternativ ein Zeichen aus Zeichenbereichen
.	beliebiges Zeichen
^	Anfang der Zeichenfolge (nichts darf vorangehen)
\$	Ende der Zeichenfolge (nichts darf darauf folgen)

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 308

Ziele:

Notation lernen

in der Vorlesung:

- Notationen vergleichen,
- bisher definierte reguläre Ausdrücke umschreiben,
- weitere Beispiele angeben.

Beispiele für reguläre Ausdrücke in PHP-Notation

Reguläre Ausdrücke kommen in PHP-Programmen immer als Zeichenreihenliterals (Strings) vor. Diese werden in " eingeschlossen, z. B. "1|0".

Statt Namen für reguläre Ausdrücke zu definieren, weisen wir die Zeichenreihe einer Variablen zu, z. B. `$binDig = "1|0"`;

Variable = regulärer Ausdruck als PHP-String

```
$Abc = "(a|b)(c|d)?";
$Anrede = "Sehr geehrte(r)? (Frau|Herr)";
$Dig = "[0-9]";
$sLet = "[a-z]";
$cLet = "[A-Z]";
$Let = "[a-zA-Z]";
$Bezeichner = "[a-zA-Z][a-zA-Z0-9]*";
$GeldBetrag = "$Dig+,$Dig{2}";
$KFZ = "$cLet{1,3}-$cLet{1,2}-$Dig{1,4}";
$Dual = "1{3}[10]*0{3}";
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 309

Ziele:

Notationen üben

in der Vorlesung:

- Notationen vergleichen,
- bisher definierte reguläre Ausdrücke umschreiben.

Beispiele für Definitionen von Grundsymbolen in PHP-Notation

```
$Pascal_Identifier = "[a-zA-Z][a-zA-Z0-9]*";
$C_Identifier = "[a-zA-Z_][a-zA-Z_0-9]*";
$ADA_Identifier = "[a-zA-Z](_[a-zA-Z0-9])?";
$PHP_Var_Identifier = "\$[a-zA-Z_][a-zA-Z_0-9]*";
$Pascal_Exponent = "((e|E)(\+|-)?[0-9]+)";
$Pascal_Real = "(((0-9]+\.[0-9]+)$Exponent?)|((0-9)+$Exponent)";
$HexDig = "[0-9a-fA-F]";
$HTML_CharRef = "&(([a-zA-Z]+)|(#[0-9]+)|(#x$HexDig+));";
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 310

Ziele:

Notationen üben

in der Vorlesung:

- Notationen vergleichen,
- bisher definierte reguläre Ausdrücke umschreiben.

E2.2 Kontextfreie Grammatiken

Kontextfreie Grammatik (KFG): formaler Kalkül zur Definition einer

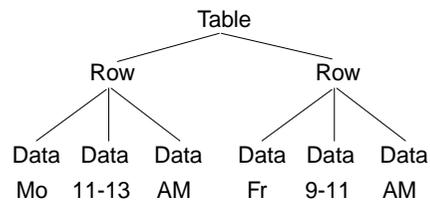
- **Sprache** als Menge von Sätzen; jeder **Satz** ist eine **Folge von Symbolen**
- **Menge von Bäumen;** jeder Baum repräsentiert die **Struktur eines Satzes** der Sprache

Anwendungen:

- Programme einer **Programmiersprache** und deren **Struktur**, z. B. Java, Pascal, C
- **Sprachen als** Schnittstellen zwischen Software-Werkzeugen, **Datenaustauschformate**, z. B. HTML, XML
- Bäume zur Repräsentation **strukturierter Daten**, z. B. in HTML

Beispiel: Tabellen in HTML:

```
<table><tr><td>Mo</td>
  <td>11-13</td>
  <td>AM</td>
</tr>
<tr> <td>Fr</td>
  <td>9-11</td>
  <td>AM</td>
</tr>
</table>
```



Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 311

Ziele:

Einsatz von KFGn kennenlernen

in der Vorlesung:

Erläuterungen zu den Anwendungen:

- Struktur von HTML-Sätzen,
- Struktur von Tabellen.
- Bäume werden noch definiert.

Definition: Kontextfreie Grammatik

Eine kontextfreie Grammatik $G = (T, N, P, S)$ besteht aus:

- T Menge der Terminalsymbole** (kurz: Terminale)
- N Menge der Nichtterminalsymbole** (kurz: Nichtterminale)
(T und N sind disjunkt)
- S Startsymbol;** S ist ein Nichtterminal: $S \in N$
- P Menge der Produktionen**
jede Produktion hat die Form $A ::= x$
A ist ein Nichtterminal, d. h. $A \in N$ und
x ist eine (evtl. leere) Folge von Terminalen und Nichtterminalen,
d. h. $x \in (T \cup N)^* = V^*$

$V = T \cup N$ heißt auch **Vokabular**, seine Elemente heißen **Symbole**

Man sagt

„In der Produktion $A ::= x$ steht A auf der **linken Seite** und x auf der **rechten Seite**.“

Man gibt Produktionen häufig **Namen**: $p_1: A ::= x$

In Symbolfolgen aus V^* werden die Elemente nur durch Zwischenraum getrennt: $A ::= B C D$

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 312

Ziele:

KFG Definition lernen

in der Vorlesung:

- Erläuterung der Begriffe am Beispiel der nächsten Folie EWS-3.13,
- Erläuterung der Notation von Produktionen
- Wir benutzen jetzt die Bezeichnungen Satz, Symbol und Vokabular statt Wort, Zeichen und Alphabet.
- Die Angabe V^* ist als regulärer Ausdruck zu verstehen, also "eine (evtl. auch leere) Folge beliebiger Symbole aus V."

Beispiel zur Definition einer KFG

Terminale $T = \{ (,) \}$
Nichtterminale $N = \{ \text{Klammern, Liste} \}$
Startsymbol $S = \text{Klammern}$
Produktionen $P =$
 $\{$
 p1: $\text{Klammern} ::= '(\text{Liste})'$
 p2: $\text{Liste} ::= \text{Klammern Liste}$
 p3: $\text{Liste} ::=$
 $\}$

Vokabular $V = T \cup N = \{ (,), \text{Klammern, Liste} \}$

Unbenannte Terminale werden in ' eingeschlossen, um Verwechslungen mit KFG-Zeichen zu vermeiden: '('

m m
 Namen **N** **V***

Diese Grammatik definiert eine Sprache, deren Sätze Folgen von geschachtelten Klammerpaaren sind, z. B.

$(())$ $((()) (()))$

Ziele:
Kleines Beispiel zum Verstehen der Definition

in der Vorlesung:
Die Begriffe der Definition von KFGn werd an diesem Beispiel erklärt:

- Im Rahmen stehen die formal notwendigen Angaben T, N, S, P.
- Vokabular und Namen von Produktionen sind zusätzliche Angaben.
- Die Menge N wird aus den Symbolen auf den linken Seiten der Produktionen gebildet.
- Symbole, die in Produktionen vorkommen, aber nicht in N sind, sind Terminale in T.
- Die Anwendung der Produktionen als Regeln zur Definition der Sprache der Grammatik folgt auf den nächsten Folien.

Bedeutung der Produktionen

Eine Produktion $A ::= x$ ist eine **Strukturregel**: A besteht aus x

Beispiele:

DeutscherSatz ::= Subjekt Prädikat Objekt
 Ein DeutscherSatz besteht aus (der Folge) Subjekt Prädikat Objekt
 Klammern ::= '(Liste)'
 Zuweisung ::= Variable ':=' Ausdruck
 Variable ::= Variable '[' Ausdruck ']'

Produktion graphisch dargestellt als gewurzelter **Baum** mit geordneten Kanten und mit Symbolen als Knotenmarken (zum Begriff „Baum“ siehe nächste Folie):



Ziele:
Produktionen verstehen

in der Vorlesung:
Erläuterungen der beiden Rollen von Produktionen:

- Definition von Struktur: "besteht aus"
- Definition von Ersetzungen
- Siehe auch spätere Folie zur graphischen Darstellung von Produktionen.

Bäume als Abstraktion

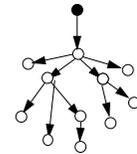
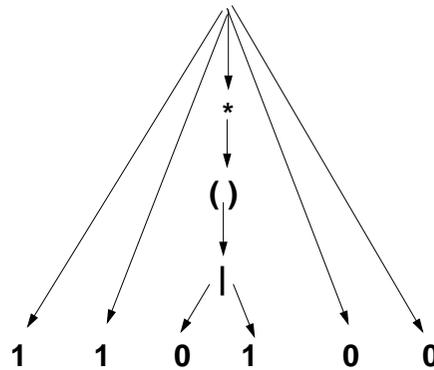
E

EWS-3.15

Bäume bezeichnen in der Informatik **abstrakte Datenstrukturen** mit speziellen Eigenschaften.

Sie werden zur abstrakten Beschreibung bestimmter Zusammenhänge eingesetzt. Ein besonders wichtiger ist die „**besteht-aus**“-Beziehung zwischen einem Objekt und seinen Teilen.

Z. B. ein regulärer Ausdruck besteht aus Teilausdrücken:



© 2003 bei Prof. Dr. Uwe Kastens

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 315

Ziele:

Bäume als Abstraktion verstehen

in der Vorlesung:

Am Beispiel wird gezeigt, wie die besteht-aus Relation durch einen Baum dargestellt wird.

Begriffe zu Bäumen

E

EWS-3.16

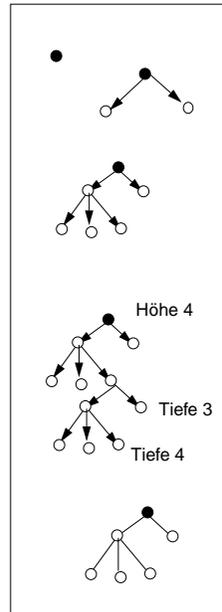
Definition: Ein (gewurzelter, gerichteter) **Baum** besteht aus

- einem **Knoten** k und
- einer (evtl. leeren) **Folge von Bäumen** und **Kanten** von k zu jedem Element der Folge.
- In **einen** Knoten mündet keine Kante, in alle anderen genau eine.

Begriffe und Eigenschaften:

- **Wurzel:** Knoten in den keine Kante mündet.
- **Blätter:** Knoten, von denen keine Kante ausgeht
- **innere Knoten:** es mündet eine Kante und es gehen welche aus
- Es gibt genau eine Wurzel.
- Wenn ein Baum n Knoten hat, dann hat er $n-1$ Kanten.
- **Tiefe eines Blattes:** Anzahl der Kanten auf dem Weg von der Wurzel zu dem Blatt.
- **Höhe des Baumes:** größte Tiefe aller seiner Blätter.

Knoten und/oder Kanten können **beschriftet** werden.
Man kann die Pfeilspitzen weglassen, wenn die Wurzel bekannt ist.



© 2006 bei Prof. Dr. Uwe Kastens

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 316

Ziele:

Definition und Begriffe zu Bäumen verstehen

in der Vorlesung:

Die Definition und die Begriffe werden an Beispielen erklärt.

Ableitungen

Produktionen sind **Ersetzungsregeln**: Ein Nichtterminal A in einer Symbolfolge u A v kann durch die rechte Seite x einer Produktion $A ::= x$ ersetzt werden.

Das ist ein **Ableitungsschritt**; er wird notiert als $u A v \Rightarrow u x v$

z. B. **Klammern Klammern Liste** \Rightarrow **Klammern (Liste) Liste**
mit Produktion p1: **Klammern** ::= **(Liste)**

Beliebig viele Ableitungsschritte nacheinander angewandt heißen **Ableitung**; notiert als $u \Rightarrow^* v$

Eine kontextfreie Grammatik **definiert eine Sprache**; das ist eine **Menge von Sätzen**.

Jeder Satz ist eine Folge von Terminalsymbolen, die aus dem Startsymbol ableitbar ist:

$$L(G) = \{ w \mid w \in T^* \text{ und } S \Rightarrow^* w \}$$

Grammatik auf EWS-3.13 definiert geschachtelte Folgen paariger Klammern als Sprachmenge:

$$\{ (), (()), (())(), ((())()), \dots \} \subseteq L(G)$$

Ableitung des Satzes $((())())$:

S	= Klammern	p1
	\Rightarrow (Liste)	p2
	\Rightarrow (Klammern Liste)	p2
	\Rightarrow (Klammern Klammern Liste)	p1
	\Rightarrow (Klammern (Liste) Liste)	p1
	\Rightarrow ((Liste) (Liste) Liste)	p3
	\Rightarrow (() (Liste) Liste)	p3
	\Rightarrow (() (Liste)	p3
	\Rightarrow (() ()	

Ableitungsbäume

Jede Ableitung kann man als gewurzelten **Baum** darstellen:

Die **Knoten** mit ihren Marken repräsentieren **Vorkommen von Symbolen**.

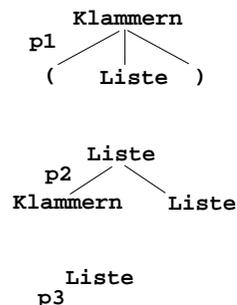
Ein Knoten mit seinen direkten Nachbarn repräsentiert die **Anwendung einer Produktion**.

Die **Wurzel** ist mit dem **Startsymbol** markiert.

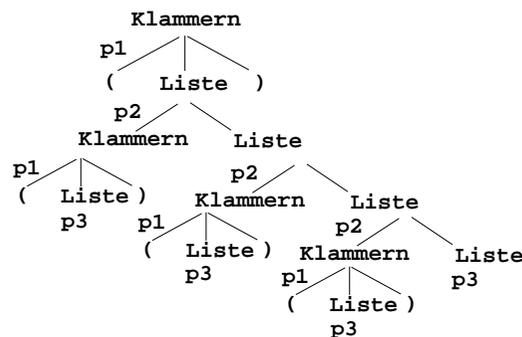
Terminale kommen nur an **Blättern** vor.

Ein Ableitungsbaum entsteht durch „Zusammensetzen von Kopien der Produktionsbäume“.

Produktionen:



ein **Ableitungsbaum:**



der Satz dazu: $((())())$

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 317

Ziele:

Ableitungsbegriff verstehen

in der Vorlesung:

Erläuterungen dazu

- Beispiele für Ableitungen
- Beispiele für Sprachen

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 318

Ziele:

Ableitungsbaum verstehen

in der Vorlesung:

- Konstruktion des Baumes durch Zusammensetzen von Produktionsanwendungen.

Satz zum Ableitungsbaum

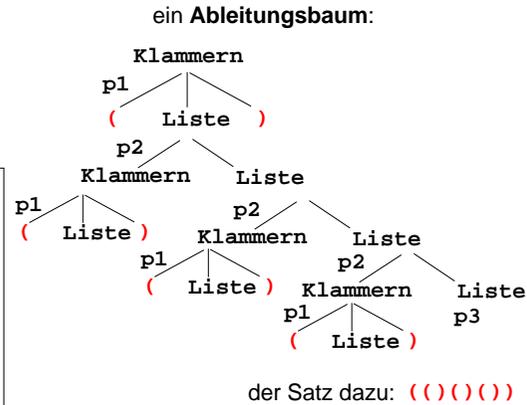
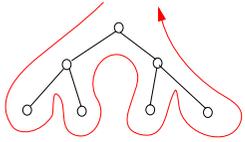
E

EWS-3.19

Man erhält den **Satz** aus einem **Ableitungsbaum**, wenn man seine **Terminale** in der Reihenfolge eines **links-abwärts Durchlaufes** aufschreibt.

Ein links-abwärts Durchlauf

- **beginnt** mit einem Besuch der **Wurzel**,
- bei dem Besuch eines Knotens werden nacheinander für jeden seiner **Unterbäume von links nach rechts** jeweils ein **links-abwärts Durchlauf** durchgeführt.



Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 319

Ziele:

Satz aus Ableitungsbaum herleiten

in der Vorlesung:

An Beispielen wird erklärt:

- rekursiv definierter Baumdurchlauf,
- Zusammenhang zum Satz der Sprache

Grammatik für arithmetische Ausdrücke

E

EWS-3.20

Grammatik für arithmetische Ausdrücke

Produktionen:

```

p1: Expr ::= Expr AddOpr Fact
p2: Expr ::= Fact
p3: Fact ::= Fact MulOpr Opd
p4: Fact ::= Opd
p5: Opd ::= '(' Expr ')'
p6: Opd ::= Ident
p7: AddOpr ::= '+'
p8: AddOpr ::= '-'
p9: MulOpr ::= '*'
p10: MulOpr ::= '/'
  
```

Beispiele:

```

b + c
a * (b + c)
a * b + c
a + b * c
  
```

$T = \{ (,), +, -, *, /, \text{Ident} \}$

$N = \{ \text{Expr}, \text{Fact}, \text{Opd}, \text{AddOpr}, \text{MulOpr} \}$

$S = \text{Expr}$

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 320

Ziele:

Kleine, realistische Grammatik verstehen

in der Vorlesung:

An Beispielen wird erklärt:

- Ableitungen und Bäume dazu bilden (mit EWS-3.21),
- Rollen der Produktionen verstehen.

Beispiel für eine Ableitung zur Ausdrucksgrammatik

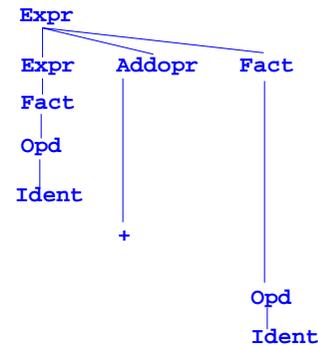
Satz der Ausdrucksgrammatik $b + c$

Ableitung:

	Expr		
p1	=> Expr	Addopr	Fact
p2	=> Fact	Addopr	Fact
p4	=> Opd	Addopr	Fact
p6	=> Ident	Addopr	Fact
p7	=> Ident	+	Fact
p4	=> Ident	+	Opd
p6	=> Ident	+	Ident

b + c

Ableitungsbaum:



b + c

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 321

Ziele:

Zusammenhang zw. Ableitung und Ableitungsbaum

in der Vorlesung:

An dem Beispiel wird erklärt:

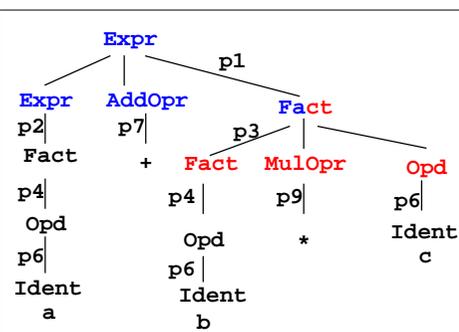
- Baum stellt Ableitungsschritte dar.
- Ableitungsschritte können in unterschiedlicher Reihenfolge ausgeführt werden,
- die Bäume dazu sind identisch.

Präzedenz und Assoziativität in Ausdrucksgrammatiken

Die Struktur eines Satzes wird durch seinen Ableitungsbaum bestimmt. Ausdrucksgrammatiken legen dadurch die **Präzedenz** und **Assoziativität** von Operatoren fest.

Im Beispiel hat **AddOpr** geringere Präzedenz als **MulOpr**, weil er **höher in der Hierarchie der Kettenproduktionen** $\text{Expr} ::= \text{Fact}$, $\text{Fact} ::= \text{Opd}$ steht.

Name	Produktion
p1:	Expr ::= Expr AddOpr Fact
p2:	Expr ::= Fact
p3:	Fact ::= Fact MulOpr Opd
p4:	Fact ::= Opd
p5:	Opd ::= '(' Expr ')'
p6:	Opd ::= Ident
p7:	AddOpr ::= '+'
p8:	AddOpr ::= '-'
p9:	MulOpr ::= '*'
p10:	MulOpr ::= '/'



Im Beispiel sind **AddOpr** und **MulOpr** links-assoziativ, weil ihre **Produktionen links-rekursiv** sind, d. h. $a + b - c$ entspricht $(a + b) - c$.

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 322

Ziele:

Struktur von Ausdrucksgrammatiken verstehen

in der Vorlesung:

Erläuterungen dazu am Beispiel:

- Präzedenz (Bindungsstärke) von Operatoren,
- Assoziativität von Operatoren,
- Kettenproduktion: genau ein Nichtterminal auf der rechten Seite.
- Zusammenhang zu Produktionen zeigen,
- Variation des Beispiels

Verständnisfragen:

- Wie ändert sich die Sprache, wenn Produktion p1 durch $\text{Expr} ::= \text{Fact '+' Fact}$ ersetzt wird? Für welche Art von Operatoren wäre das sinnvoll?

Schemata für Ausdrucksgrammatiken

Ausdrucksgrammatiken konstruiert man **schematisch**, sodass **strukturelle Eigenschaften** der Ausdrücke definiert werden:

eine Präzedenzstufe, binärer Operator, linksassoziativ:

```
A ::= A Opr B
A ::= B
```

eine Präzedenzstufe, binärer Operator, rechtsassoziativ:

```
A ::= B Opr A
A ::= B
```

eine Präzedenzstufe, unärer Operator, präfix:

```
A ::= Opr A
A ::= B
```

eine Präzedenzstufe, unärer Operator, postfix:

```
A ::= A Opr
A ::= B
```

Elementare Operanden: nur aus dem Nichtterminal der höchsten Präzedenzstufe (sei hier H) abgeleitet:

```
H ::= Ident
```

Geklammerte Ausdrücke: nur aus dem Nichtterminal der höchsten Präzedenzstufe (sei hier H) abgeleitet; enthalten das Nichtterminal der niedrigsten Präzedenzstufe (sei hier A)

```
H ::= '(' A ')'
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 323

Ziele:

Schemata erkennen können

in der Vorlesung:

Erläuterungen dazu

Übungsaufgaben:

Anwenden der Schemata zum Verstehen von Ausdrucksgrammatiken

Nützliche Grammatik-Konstrukte

beliebig lange Folgen von `stmt` z. B. in:

```
Block ::= '{' stmts '}'
stmts ::= stmts stmt
stmts ::=
```

Abkürzung für **beliebig lange Folgen**:

```
Block ::= '{' stmt* '}'
```

Die 2 Produktionen für `stmts` entfallen.

nicht leere Folgen von `stmt`:

```
stmts ::= stmts stmt
stmts ::= stmt
```

Entsprechend für **nicht-leere Folgen**:

```
Block ::= '{' stmt+ '}'
```

nicht-leere Folgen von `stmt` **getrennt durch ;**:

```
stmts ::= stmts ';' stmt
stmts ::= stmt
```

Alternative Produktionen für dasselbe Nichtterminal mit `|` zusammenfassen, z. B.

```
stmts ::= stmts ';' stmt |
        stmt
```

Optionale Parameter z. B. in:

```
Call ::= Name '(' ParamOpt ')'
ParamOpt ::= Parameter
ParamOpt ::=
```

Optionales mit `[]` klammern, z. B.

```
Call ::= Name '(' [ Parameter ] ')'
Die 2 Produktionen für ParamOpt entfallen.
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 324

Ziele:

Produktionen für Folgen und Optionen verstehen

in der Vorlesung:

Die Konstrukte und Abkürzungen werden an Beispielen erklärt:

- Beispiele für Sätze aus Block und Call ableiten.
- * und + mit regulären Ausdrücken vergleichen.

Ausschnitte aus einer HTML-Grammatik

Die **Syntax von HTML** ist im Kalkül der „Document Type Definition (DTD)“ formal definiert. Man kann **Ausschnitte zu einigen Aspekten** von HTML in **KFGn** übertragen. Es folgen Beispiele dafür.

Grundstruktur (ohne Attribute innerhalb von Tags):

```
HTMLDoc ::= '<html>' '<head>' HeadContent '</head>'
          '<body>' Block '</body>'
          '</html>'

Block ::= Paragraph | Table | List | Heading | ...

Paragraph ::= '<p>' Inline ['</p>']

Inline ::= ... Fließtext mit Auszeichnungen ohne Blockstrukturen ...

Flow ::= Block | Inline
```

```
Tabellen: Table ::= '<table>' Row* '</table>'
           Row  ::= '<tr>' Cell* '</tr>'
           Cell ::= '<td>' Flow '</td>'
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 325

Ziele:

Produktionen aus einer größeren Grammatik verstehen

in der Vorlesung:

An bekannten Beispielen aus HTML wird erklärt:

- Bedeutung der Produktionen,
- Verwendung von Grammatikkonstrukten,
- Klassifikation in Block und Inline und Zusammenfassung zu Flow,
- Tabellenstruktur,
- Hinweis auf DTD für HTML beim W3C.

HTML-Grammatik: Listen und Attribute

Listen:

```
List ::= '<ol>' ListElement+ '</ol>' |
        '<ul>' ListElement+ '</ul>'

ListElement ::= '<li>' Flow '</li>'
```

Attribute in Anfangs-Tags.

In dieser Grammatik werden Tags weiter zerlegt:

```
AnfangsTag ::= '<' TagName Attribute* '>'

Attribute ::= AttributeName '=' AttributeValue

AttributeName ::= Identifier

AttributeValue ::= StringLiteral | Identifier | Number | ...
```

Vorlesung Einführung in Web-bezogene Sprachen WS 2006 / Folie 326

Ziele:

HTML-Konstrukte an Grammatikregeln verstehen

in der Vorlesung:

An bekannten Beispielen aus HTML wird erklärt:

- Bedeutung der Produktionen,
- Verwendung von Grammatikkonstrukten,
- Struktur von Listen in HTML,
- Notation der Attribute in HTML.