Parser

(Compiler)

Prof. Dr. Oliver Braun

Letzte Änderung: 17.05.2017 11:06

Parsing

- Parsing ist die zweite Stufe im Compiler-Frontend
- Eingabe ist der Wörterstrom den der Scanner erzeugt
- der Parser versucht mit Hilfe eines grammatikalischen Models eine syntaktische Struktur für das Programm herzuleiten
- wenn der Parser erkennt, dass die Eingabe ein gültiges Programm ist
  - erzeugt er ein konkretes Modell des Programms
- wenn die Eingabe nicht gültig ist, meldet er das Problem und die dazu gehörigen diagnostischen Informationen
- Parsing hat als Problemstellung viele Ähnlichkeiten mit dem Scanning
- die theoretische Grundlage für Parsertechnologien wurde sehr ausführlich als Teilgebiet der formalen Sprachtheorie untersucht

Syntax

- wir benötigen eine Notation mit Hilfe derer wir die Syntax einer Sprache beschreiben und Programme dagegen prüfen können
- ein möglicher Kandidat sind reguläre Ausdrücke
- aber REs sind nicht mächtig genug die komplette Syntax zu beschreiben (Beispiel siehe folgende Folie)
- vielversprechender ist die kontextfreie Grammatik (*context-free grammar (CFG)*)

Warum keine regulären Ausdrücke?

- denken wir an das Problem arithmetische Ausdrücke mit Variablen und Operatoren zu erkennen
- der RE
  $[a...z]([a...z]|[0...9])^*((+|-|\times|\div)[a...z]([a...z]|[0...9])^*)^*$
  - enthält keinerlei Informationen über den Vorrang von Operatoren, z.B. bei $a + b \times c$
- wir können versuchen Klammern mit zu erkennen:

  $(\backslash(|\epsilon)[a...z]([a...z]|[0...9])^*((+|-|\times$
  $|\div)[a...z]([a...z]|[0...9])^*)^*(\backslash)|\epsilon)$
  - dieser RE kann ein Klammerpaar um einen Ausdruck erkennen, aber keine inneren Klammerpaare

Wirklich keine regulären Ausdrücke?

- nächster Versuch, Klammern im Abschluß:

  $$(\backslash(|\epsilon)[a...z]([a...z]|[0...9])^*((+|-|\times \\ |\div)[a...z]([a...z]|[0...9])^*\backslash)|\epsilon))^*$$

  - aber das würde $a + b) \times c)$ akzeptieren
- tatsächlich können wir keinen RE schreiben, der alle Ausdrücke mit korrekt angeordneten Klammerpaaren erkennen würde und die anderen nicht
- PCREs sind mächtiger, aber auch nicht ausdrucksstark genug

Kontextfreie Grammatik

- eine kontextfreie Grammatik G ist ein Quadrupel (T, NT, S, P) für das gilt
  - T ist die Menge von terminalen Symbolen oder Wörtern der Sprache $L(G)$. Terminale Symbole entsprechen den syntaktischen Kategorien die der Scanner ermittelt.
  - NT ist die Menge der nichtterminalen Symbolen die in den Produktionsregeln von G vorkommen. Nichtterminale Symbole sind syntaktische Variablen.
  - S ist ein nichtterminales Symbol das als Startsymbol dient.
  - P ist die Menge von Produktionsreglen von G. P hat die Form $NT \mapsto (T \cup NT)^+$

Backus-Naur-Form

- üblicherweise werden die Produktionsregeln einer CFG in Backus-Naur-Form (BNF) angegeben
- oft genutzt werden:
  - Extended BNF (EBNF) [ISO standard]
  - Augmented BNF (ABNF) [RFC]

Beispiele

- die Sprache der Schafe:

SheepNoise	$\mapsto$	`baa` *SheepNoise*
	|	`baa`

- eine Sprache von arithmetischen Ausdrücken mit Klammern

1	*Expr*	$\mapsto$	(*Expr*)
2		|	*Expr Op* `name`
3		|	`name`
4	*Op*	$\mapsto$	+
5		|	-
6		|	*
7		|	/

Arithmetische Ausdrücke in Haskell

siehe https://github.com/ob-cs-hm-edu/compiler-ParserArithExpr

Eine Beispiel-Herleitung

- mit dem Startsymbol *Expr* können wir den Satz $(a + b) * c$ mit einer rechtskanonischen Ableitung (*rightmost derivation*) herleiten, durch die Sequenz (2,6,1,2,4,3)

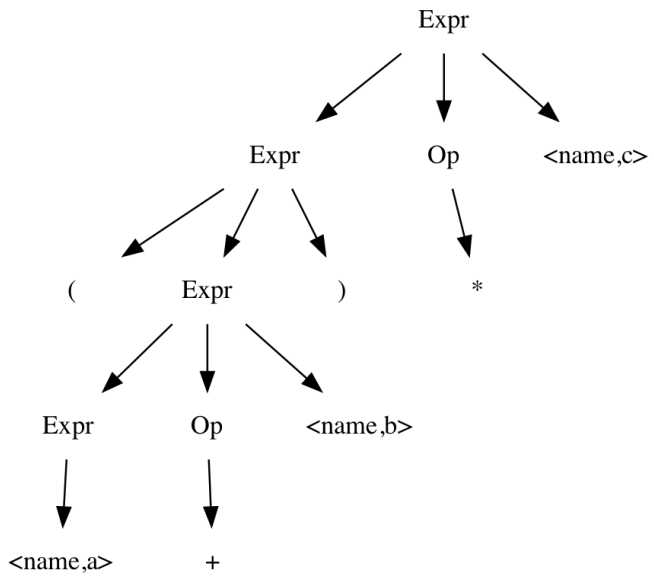

- die linkskanonische Ableitung (*leftmost derivation*) nutzt die Sequenz (2,1,2,3,4,6) und resultiert offensichtlich im selben Parsebaum

Mehrdeutige Grammatik

- für einen Compiler ist es wichtig, dass jeder Satz eine eindeutige (rechts- oder linkskanonische) Herleitung hat
- wenn es verschiedene Herleitungen für einen Satz gibt, heißt die Grammatik mehrdeutig
- eine solche Grammatik kann für einen Satz verschiedene Parsebäume erzeugen, die potentiell verschiedene Bedeutungen eines Programmes bedeuten können

Der Klassiker für eine mehrdeutiges Konstrukt

1	*Statement*	$\mapsto$	`if` *Expr* `then` *Statement* `else` *Statement*
2		|	`if` *Expr* `then` *Statement*
3		|	*Assignment*
4		|	*...other statements...*

.. kann in diesen Parsebaum resultieren:

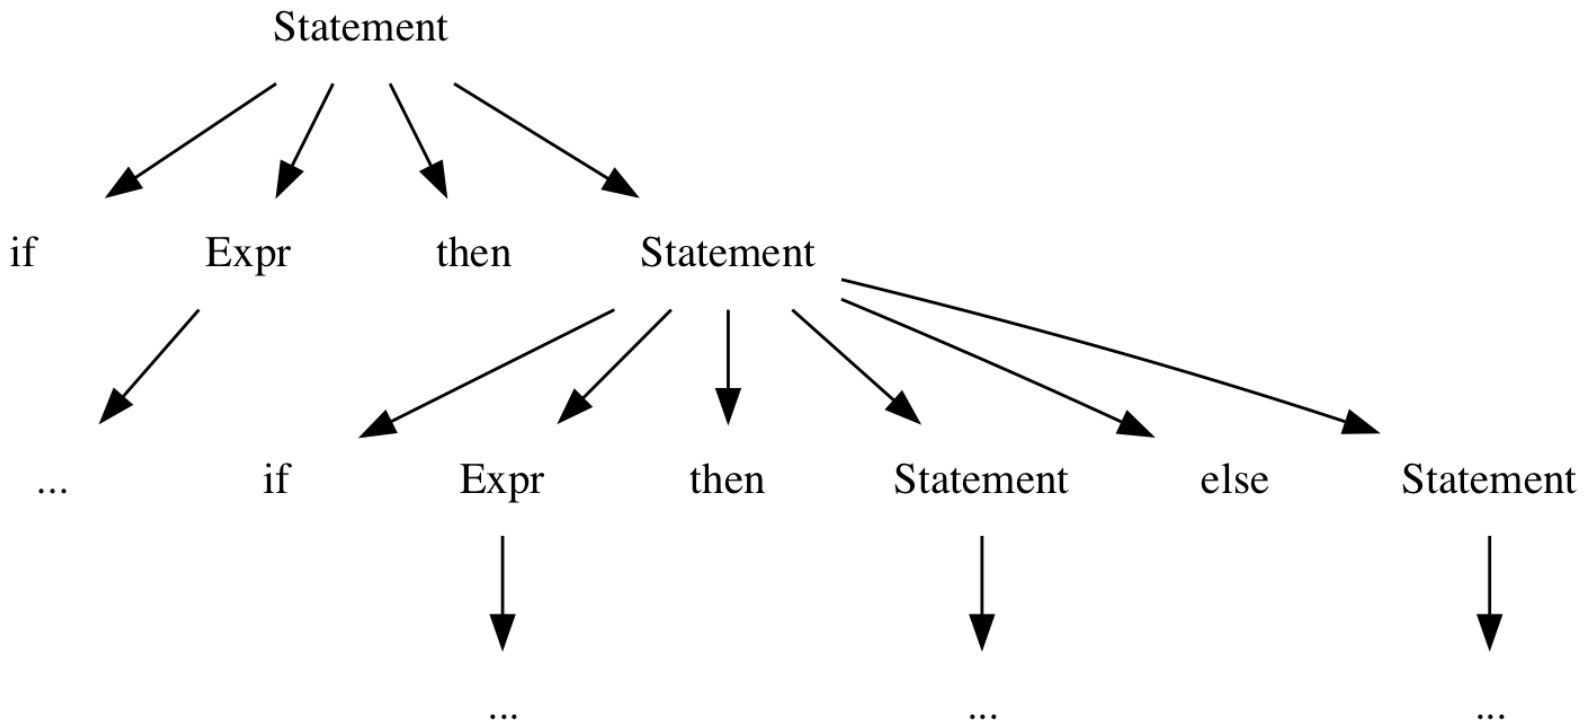

.. oder in diesen

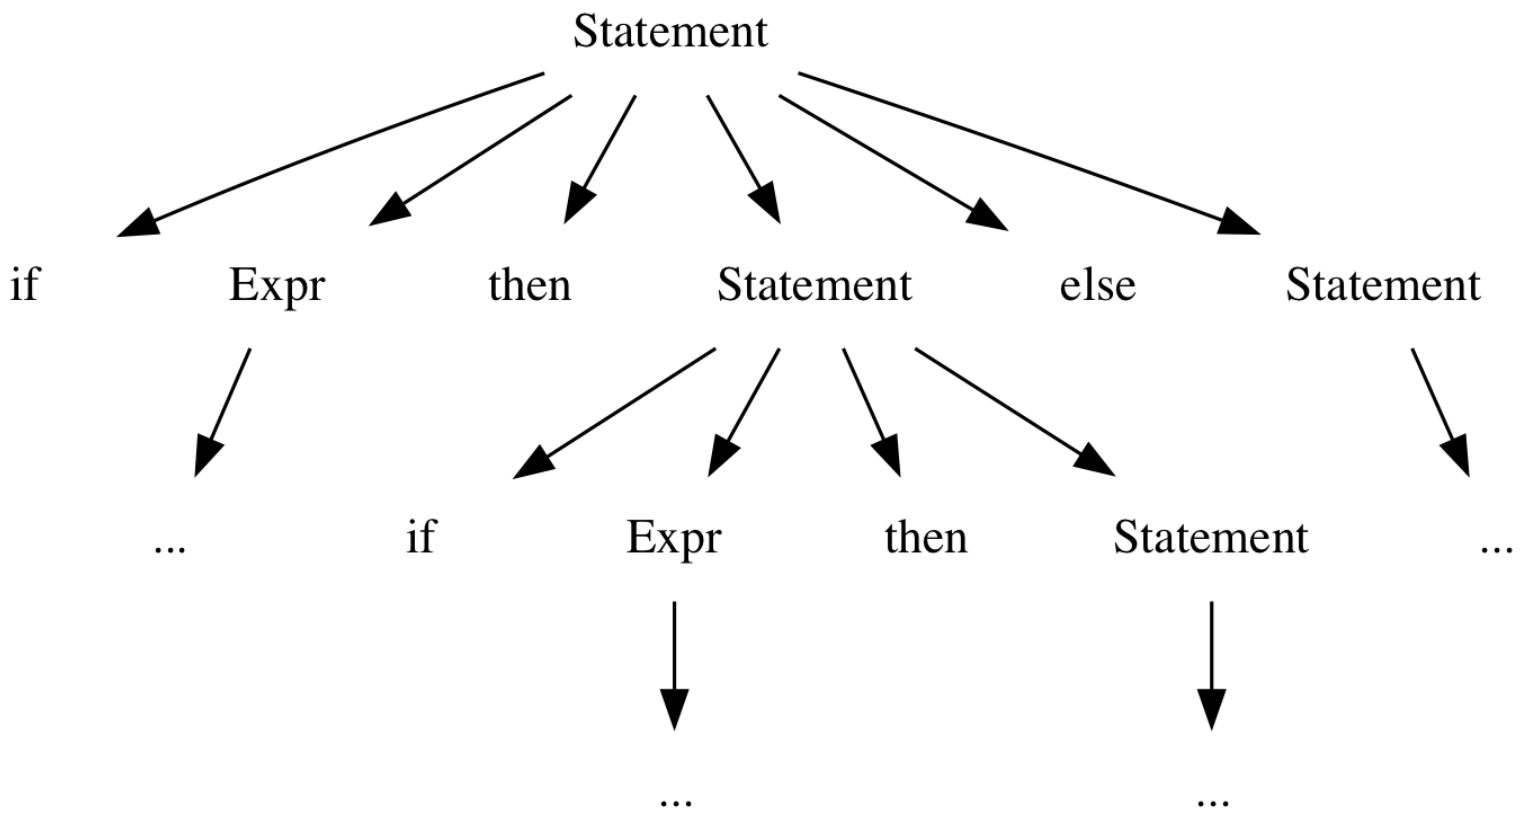

`else` ohne Mehrdeutigkeit

1	*Statement*	$\mapsto$	`if` *Expr* `then` *Statement*
2		$\mid$	`if` *Expr* `then` *WithElse* `else` *Statement*
3		$\mid$	*Assignment*
4		$\mid$	*...other statements...*
5	*WithElse*	$\mapsto$	`if` *Expr* `then` *WithElse* `else` *WithElse*
6		$\mid$	*Assignment*

Bedeutung in Struktur kodieren

- Parsen von $a + b * c$ resultiert mit den o.a. Regeln in

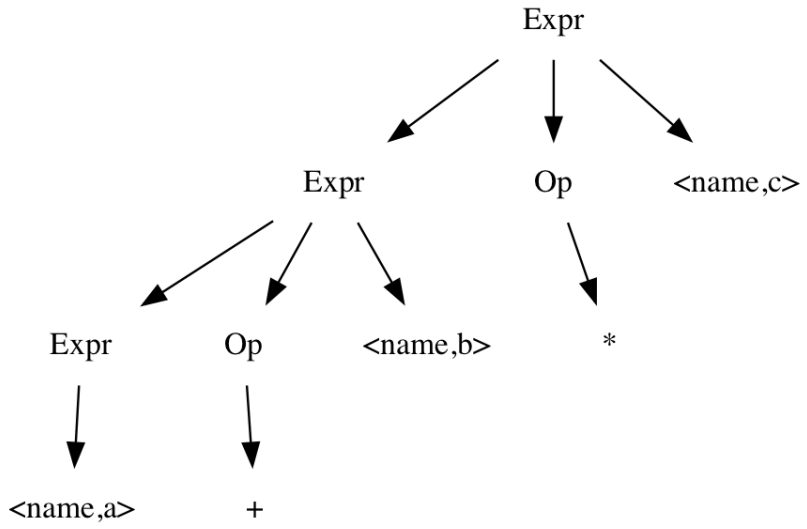

- ein naheliegender Ansatz den Ausdruck auszuwerten ist den Baum "Postorder" zu durchlaufen
- aber das resultiert in $(a + b) * c$ und nicht $a + b * c$, da wir bislang keinen Vorrang der Operatoren in der Grammatik formuliert haben

Operator Vorrang hinzufügen

0	*Goal*	$\mapsto$	*Expr*
1	*Expr*	$\mapsto$	*Expr* + *Term*
2		|	*Expr* - *Term*
3		|	*Term*
4	*Term*	$\mapsto$	*Term* * *Factor*
5		|	*Term* / *Factor*
6		|	*Factor*
7	Factor	$\mapsto$	(*Expr*)
8		|	`num`
9		|	`name`

Parsen mit den neuen Regeln

Durch die Sequenz (0,1,4,6,9,9,3,6,9) bekommen wir jetzt den Parsebaum:

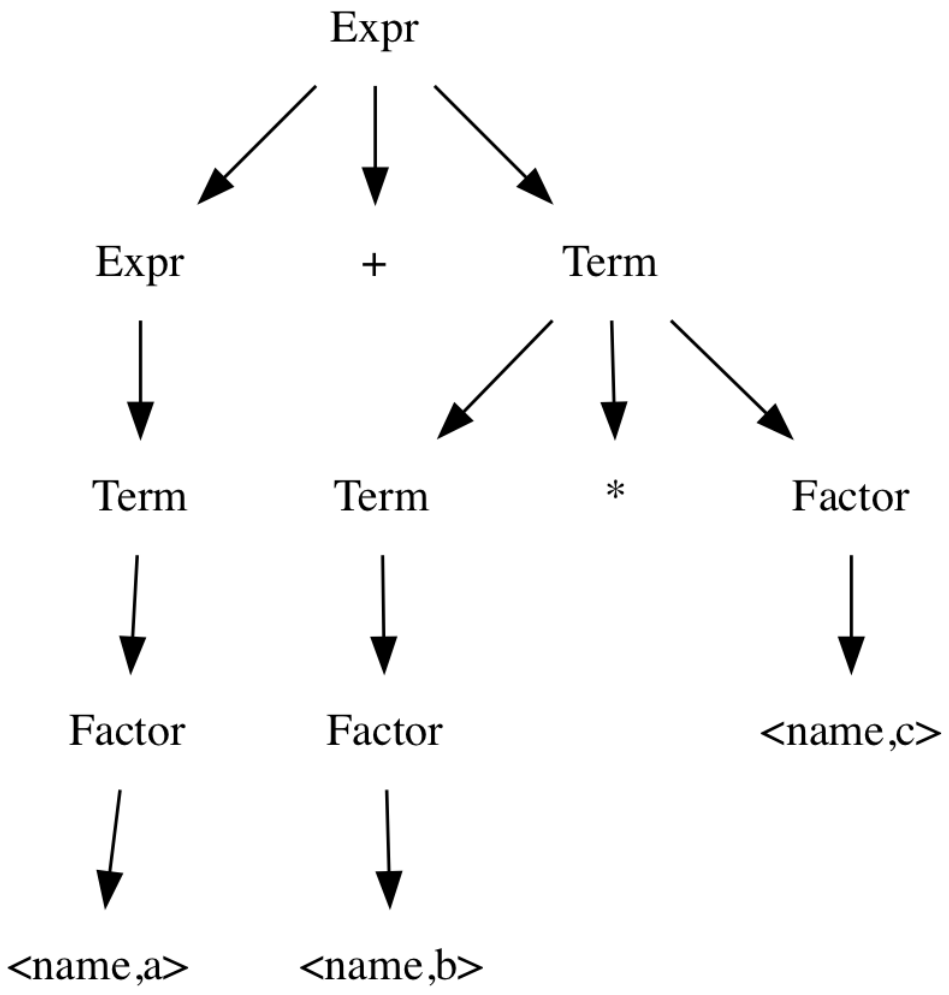

Top-Down Parsing

- ein Top-Down Parser beginnt an der Wurzel des Parsebaumes und erweitert ihn systematisch nach unten
- er wählt Nichtterminale am unteren Rand des Baumes aus und erweitert ihn indem er Kindknoten hinzufügt die den Regeln entsprechen
- der Prozess wird solange fortgesetzt bis entweder
  a) der untere Rand des Baumes nur terminale Symbole enthält **und** der Eingabestrom zuende ist, oder
  b) ein klarer Mismatch zwischen dem unteren Rand und dem Eingabestrom entstanden ist.
- im ersten Fall war der Parser erfolgreich
- im zweiten Fall
  - könnte der Parser in einem früheren Schritt eine falsche Regel ausgewählt haben. Er kann durch *Backtracking* dort hin zurück und mit einer anderen Regel weiter machen

Top-Down Parsing ...

- Top-Down Parsing ist für eine große Teilmenge der CFGs, die ohne Backtracking auskommt, effizient
- es gibt Transformationen die *in vielen Fällen* eine beliebige Grammatik in eine Grammatik umwandeln kann, die ohne Backtracking aus kommt
- es gibt zwei verschiedene Ansätze um Top-Down Parser zu bauen:
  1. Handgeschriebene rekursiv-absteigende Parser (*hand-coded recursive-descent parsers*), und
  2. generierte LL(1) Parser

Linksrekursion eliminieren

- eine linkskanonischer Top-Down Parser kann in eine Endlosschleife geraten, wenn die Grammatik *Linksrekursion* enthält, z.B.

Fee	$\mapsto$	*Fee* α
	$\mid$	β

- diese können wir aber einfach eliminieren durch beispielsweise

Fee	$\mapsto$	β *Fee'*
Fee'	$\mapsto$	α *Fee'*
	$\mid$	ϵ

Aufgabe

Eliminieren Sie die Linksrekursion

0	*Goal*	$\mapsto$	*Expr*
1	*Expr*	$\mapsto$	*Expr* + *Term*
2		|	*Expr* - *Term*
3		|	*Term*
4	*Term*	$\mapsto$	*Term* * *Factor*
5		|	*Term* / *Factor*
6		|	*Factor*
7	Factor	$\mapsto$	(*Expr*)
8		|	`num`
9		|	`name`

Lösung

0	*Goal*	$\mapsto$	*Expr*
1	*Expr*	$\mapsto$	*Term Expr'*
2	*Expr'*	$\mapsto$	+ *Term Expr'*
3		|	- *Term Expr'*
4		|	ϵ
5	*Term*	$\mapsto$	*Factor Term'*
6	*Term'*	$\mapsto$	* *Factor Term'*
7		|	/ *Factor Term'*
8		|	ϵ
9	*Factor*	$\mapsto$	(*Expr*)
10		|	`num`
11		|	`name`

Backtrack-Free Parser

- das Hauptproblem das zu ineffizientem, linkskanonischem Top-Down Parsen führen kann, ist Backtracking
- Backtracking kann vermieden werden, wenn der Parser immer die “richtige” Regel auswählt
- für die vorherige Grammatik, kann der Parser beides, das fokusierte Symbol und das nächste Eingabesymbol, in Betracht ziehen, um die nächste Regel auszuwählen
- das nächste Eingabesymbol heißt **lookahead symbol**
- wir können also sagen, dass eine Grammatik frei von Backtracking ist mit einem Symbol lookahead
- Eine solche Grammatik heißt auch *Predictive Grammar*

Linksfaktorisierung zum Eliminieren von Backtracking

- erweitern wir unsere Grammatik durch die folgenden Regeln

11	*Factor*	$\mapsto$	`name`
12		$\mid$	`name` [*ArgList*]
13		$\mid$	`name` (*ArgList*)
15	*ArgList*	$\mapsto$	*Expr MoreArgs*
16	*MoreArgs*	$\mapsto$	, *Expr MoreArgs*
17		$\mid$	ϵ

- mit einem Lookahead von `name` kann der Parser nicht entscheiden ob er Regel 11, 12 oder 13 nehmen soll
- durch Linksfaktorisierung können wir die Regel ändern in:

11	*Factor*	$\mapsto$	`name` *Arguments*
12	*Arguments*	$\mapsto$	[*ArgList*]
13		$\mid$	(*ArgList*)
14		$\mid$	ϵ

Top-Down rekursiv-absteigende Parser

- Backtracking-freie Grammatiken eignen sich zum einfachen und effizienten Parsen mit rekursiv-absteigenden Parsern
- ein rekursiv-absteigender Parser wird durch eine Menge sich gegenseitig rekursiv aufrufender Prozeduren, eine für jedes nichtterminale Symbol der Grammatik
- gegeben seien die drei folgenden Regeln:

2	*Expr'*	$\mapsto$	+ *Term Expr'*
3		|	- *Term Expr'*
4		|	ϵ

- um Instanzen von *Expr'* zu erkennen, wird eine Prozedur `EPrime()` impelemtiert
  - die eine Regel gem. dem Lookahead Symbol auswählt
  - und in Abhängigkeit davon `NextWord()` und die entsprechende Prozedur aufruft

Table-driven LL(1) Parsers

- mit Tools können automatisch effiziente Top-Down Parser für Backtracking-freie Grammatiken generiert werden
- die erzeugten Parser heissen LL(1) Parser weil
  - sie die Eingabe von **l**inks nach rechts verarbeiten,
  - eine **l**inkskanonische Ableitung konstruieren und
  - ein Lookahead von **1** Symbol nutzen.
- Grammatiken die nach einem LL(1)-Schema arbeiten, heissen **LL(1) Grammatiken** und sind, per Definition, frei von Backtracking
- die am meisten verbreitetste Implementierungstechnik nutzt einen *table-driven skeleton parser*

Bottom-Up Parsing

- Bottom-Up Parser erzeugen den Parsebaum indem sie an den Blättern starten und sich nach oben zur Wurzel arbeiten
- der Parser erzeugt für jedes Wort das der Scanner liefert ein Blatt
- um eine Ableitung zu erzeugen, fügt der Parser an der oberen Grenze eine Schicht von Nichtterminalen über die Blätter
- der Parser sucht an der oberen Grenze nach einer Zeichenkette die zur rechten Seite einer Produktionsregel $A \mapsto \beta$ passt
- wenn er β findet, erzeugt er einen Knoten für A und verbindet die Knoten die β repräsentieren mit A als Kindknoten
- das Vorgehen nennen wir **Reduktion**, weil es die Anzahl der Knoten an der oberen Grenze reduziert
- das Ersetzen von β durch A an der Position k wird geschrieben $\langle A \mapsto \beta, k \rangle$ und heißt ein **Handle**

Bottom-Up Parsing...

- der Bottom-Up Parser wiederholt diesen einfachen Prozess
- er findet ein Handle $\langle A \mapsto \beta, k \rangle$ an der oberen Grenze
- er ersetzt das Vorkommen von β bei k mit A
- dieser Prozess wiederholt sich bis entweder
  1. er die gesamte Grenze zu einem einzigen Knoten ersetzt, der das Startsymbol der Grammatik repräsentiert oder
  2. er kein Handle findet.
- im ersten Fall hat der Parser eine Herleitung gefunden und, wenn er bereits den gesamten Eingabestrom verbraucht hat, ist erfolgreich
- im zweiten Fall meldet der Parser einen Fehler
- in vielen Fällen kann der Parser aber trotz Fehler weiter machen (error recovery) und so in einem Lauf möglichst viele Fehler finden

Beziehung zwischen dem Parsen und der Herleitung

- der Bottom-Up Parser arbeitet vom fertigen Satz zum Startsymbol
- die Herleitung beginnt mit dem Startsymbol un arbeitet bis zum fertigen Satz
- der Parser findet die Herleitung also rückwärts
- der Scanner ermittelt die Wörter von links nach rechts
- ein Bottom-Up Parser sucht nach der von rechtskanonischen Ableitung
- für eine Herleitung

  $Goal = \gamma_0 \mapsto \gamma_1 \mapsto \gamma_2 \mapsto ... \mapsto \gamma_{n-1} \mapsto \gamma_n = sentence$

  findet der Parser $\gamma_i \mapsto \gamma_{i+1}$ bevor er $\gamma_{i-1} \mapsto \gamma_i$ findet

LR(1) Parser

- die rechtskanonische Ableitung ist eindeutig, wenn die Grammatik keine Mehrdeutigkeiten enthält
- für eine große Klassen eindeutiger Grammatiken ist γ_{i-1} direkt durch γ_i und ein kleines bißchen Lookahead bestimmt
- für solche Grammatiken können wir einen effizienten Algorithmus zum Finden von Handles konstruieren
- die Technik dazu heißt LR-Parsing
- ein LR(1)-Parser liest den Eingabestrom von links nach rechts um eine rechtskanonische Ableitung rückwärts herzuleiten
- der Name LR(1) bezieht sich auf
  - **L**eft-to-right scan,
  - **R**everse rightmost derivation, und
  - **1** symbol of lookahead.

Praktische Parsing-Probleme

Error Recovery

- ein Parser sollte soviele Syntaxfehler wie möglich in einem Durchgang finden
- dazu benötigen wir einen Mechanismus mit dem der Parser nach einem Fehler wieder in einen Zustand kommen kann aus dem er weiter parsen kann
- ein üblicher Ansatz ist ein oder mehrere Wörter zu wählen mit denen der Parser den Eingabestrom wieder mit seinem internen Zustand synchronisieren kann
- wenn der Parser einen Fehler findet, verwirft er solange Eingabesymbole, bis er ein solches Synchronisierungswort findet

Semikolons finden

- in Sprachen die ein Semikolon verwenden um Anweisungen von einander zu trennen, braucht der Parser nur alles bis zum nächsten Semikolon verwerfen
- in einem rekursiv-absteigenden Parser kann der Code einfach die Wörter bis dahin ignorieren
- bei einem LR(1)-Parser ist das etwas komplexer
- bei einem table-driven Parser muss der Compiler dem Parsergenerator sagen können wo er synchronisieren kann
  - das kann durch "Fehlerproduktionsregeln" erreicht werden — eine Produktionsregel bei der die rechte Seite ein reserviertes Wort enthält, dass die Fehlersynchronisation anzeugt und ein oder mehrere Synchronisationstokens

Unäre Operatoren

- es ist nicht ganz einfach unäre Operatoren zur Expression-Grammatik hinzuzufügen
- fügen wir z.B. den unären Absolutbetragsoperator $||$ mit höherem Vorrang als die binären Operatoren und geringerem Vorrang als Klammern hinzu

Unäre Operatoren — Beispiel

0	*Goal*	$\mapsto$	*Expr*
1	*Expr*	$\mapsto$	*Expr* + *Term*
2		|	*Expr* - *Term*
3		|	*Term*
4	*Term*	$\mapsto$	*Term* * *Factor*
5		|	*Term* / *Factor*
6		|	*Value*
7	*Value*	$\mapsto$	|| *Factor*
8		|	*Factor*
9	Factor	$\mapsto$	(*Expr*)
10		|	`num`
11		|	`name`

- diese Grammatik erlaubt beispielsweise nicht $||\,||x$ zu schreiben

Kontextsensitive Mehrdeutigkeit

- das Benutzen eines Wortes um mehrere Bedeutungen zu repräsentieren, kann syntaktische Uneindeutigkeit hervorrufen
- ein Beispiel gab es in einigen frühen Programmiersprachen, wie z.B. Fortran, PL/I und Ada
- diese Sprachen nutzen runde Klammern für beides
  - Zugriff auf Element eines Arrays über den Index
  - Parameterlisten von Prozeduren und Funktionen
- bei `foo(i,j)` konnte der Compiler also nicht feststellen ob `foo` ein zweidimensionales Array oder eine Prozedur/Funktion ist
- der Scanner klassifizierte `foo` einfach nur als `name`

Ein Ansatz um das Problem zu lösen

umschreiben der Grammatik, so dass Funktionsaufruf und Array-Referenz eine einzige Produktion sind

- das Problem ist dann in einen späteren Schritt der Übersetzung verschoben
- es kann dann mit Hilfe von Informationen aus Deklarationen gelöst werden
- der Parser muss eine Repräsentation konstruieren, die alle später notwendigen Informationen enthält
- der spätere Schritt schreibt dies dann noch einmal um

Ein zweiter Ansatz um das Problem zu lösen

der Scanner kann die Bezeichner gemäß ihrer deklarierten Typen klassifizieren

- das setzt eine Zusammenarbeit zwischen Scanner und Parser voraus
- solange die Sprache die "define-before-use"-Regel befolgt, ist das problemlos machbar
- die Deklaration wird dann ja vor dem Scannen des Ausdrucks bereits geparst
- der Parser kann seine interne Symboltabelle dem Scanner zur Verfügung stellen um Bezeichner in verschiedene Klassen einzuteilen, z.B. `variable-name` und `function-name`

Links vs. Rechtsrekursion

- Top-Down Parser brauchen rechtsrekursive Grammatiken, Bottom-Up Parser können mit beiden arbeiten
- der Compilerbauer muss auswählen
- verschiedene Faktoren beeinflussen die Entscheidung:

  Stacktiefe im allgemeinen kann Linksrekursion mit geringeren Stacktiefen zurecht kommen

  Assoziativität Linksrekursion erzeugt auf natürliche Weise Linksassoziativität, Rechtsrekursion erzeugt Rechtassoziativität