Programmierkurs Python II

Michaela Regneri & Stefan Thater
FR 4.7 Allgemeine Linguistik (Computerlinguistik)
Universität des Saarlandes

Sommersemester 2010

Grammatiken

- Grammatiken generieren Wörter (Sätze)

S → NP VP	DET → der
NP → DET N	DET → das
NP → NP PP	N → student
PP → P NP	N → buch
VP → V	N → bibliothek
VP → V NP	V → arbeitet
VP → VP PP	V → liest
	P → in

- *Der Student arbeitet*
- *Der Student arbeitet in der Bibliothek*
- *Der Student liest das Buch*
- *Der Student liest das Buch in der Bibliothek*
- *[…]*

Kontextfreie Grammatiken

- Kontextfreie Grammatrik G = ⟨N, T, R, S⟩
  - Nichtterminalsymbole N
  - Terminalsymbole T
  - Startsymbol S ∈ N
  - Endliche Menge von Regeln: R ⊆ N x (N ∪ T)*

Übergangsrelation

- $x \Rightarrow_G y$ gdw. es gibt u, v, w, z ∈ (N ∪ T)* so dass
  - x = uvw
  - y = uzw
  - v → z ∈ R
- Sprechweise:
  - x geht (unter G) unmittelbar in y über

Ableitungen

- Eine Ableitung von y aus x (in G) ist eine Folge
  - $x = w_1 \Rightarrow w_2 \Rightarrow \ldots \Rightarrow w_n = y$
- Die durch G erzeugte Sprache:
  - $L(G) = \{ w \in T^* \mid S \Rightarrow_G^* w \}$
  - $\Rightarrow_G^*$ ist die reflexive, transitive Hülle von $\Rightarrow_G$

Linksableitungen

- Linksableitung: in jedem Ableitungsschritt wird das am weitesten links stehende Nichtterminalsymbol ersetzt.
- $x \Rightarrow_L y$ gdw. es gibt A ∈ N, a, b ∈ (N ∪ T)*, w ∈ T*
  - x = wAb
  - y = wab
  - A → a ∈ R
- Rechtsableitungen: analog

Ableitungsbäume

- Kontextfreie Grammatik $G = \langle N, T, R, S \rangle$
- Ableitungsbäume: Bäume mit folgenden Eigenschaften
  - Innere Knoten sind mit Symbolen aus N beschriftet
  - Blattknoten sind mit Symbolen aus $T \cup \{\varepsilon\}$ beschriftet
  - Wenn v ein Knoten mit Beschriftung A und Kindern $v_1, \ldots, v_n$ mit Beschriftungen $A_1, \ldots, A_n$ ist, dann ist $A \to A_1 \ldots A_n$ eine Regel aus G
  - Wenn ein Blatt mit ε beschriftet ist, dann ist das Blatt das einzige Kind seiner Mutter

Satz (siehe Lewis & Papamitriou)

- Sei $G = \langle N, T, R, S \rangle$ eine kontextfreie Grammatik.
- Folgenden Aussagen sind äquivalent:
  - $A \Rightarrow^*_G w = w_1 \ldots w_n$
  - Es gibt Ableitungsbaum mit Wurzel A und Ertrag w
  - Es gibt eine Linksableitung $A \Rightarrow_L^* w$
  - Es gibt eine Rechtsableitung $A \Rightarrow_R^* w$

Mehrdeutigkeit

- Eine Grammatik G ist eindeutig, wenn es zu jedem Wort aus L(G) genau einen Ableitungsbaum gibt.
- Sonst heißt G mehrdeutig.

Erkenner & Parser

- Erkenner (Recognizer)
  - Ist Eingabekette (Wort) $w_1 \ldots w_n \in L(G)$?
- Parser:
  - Welche Ableitungsstruktur(en) hat $w_1 \ldots w_n$?

Elementare Parsing-Strategien

- Ein Top-Down Algorithmus …
  - geht vom Startsymbol aus,
  - wendet Regel von links nach rechts an,
  - und gleicht Terminalsymbole mit der Eingabekette ab.

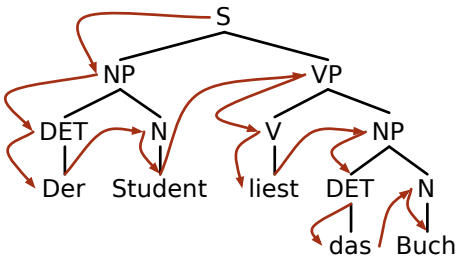

Elementare Parsing-Strategien

- Ein Bottom-Up Algorithmus …
  - geht von der Eingabekette aus
  - wendet Regeln „rückwärts“ an, wenn die rechte Seite der Regel auf die Eingabe passt,
  - bis das Startsymbol abgeleitet wurde.

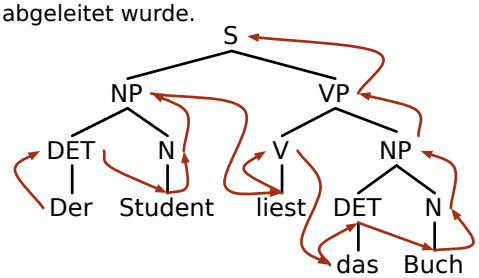

Shift-Reduce Parsing (Bottom-up)

- Initiale Konfiguration für Eingabekette $w_1 \ldots w_n$:
  - $\langle [], [w_1, \ldots, w_n] \rangle$
- Akzeptierende Konfiguration:
  - $\langle [S], [] \rangle$
- In jedem Schritt kann eine Shift- oder Reduce-Operation ausgeführt werden (nichtderterministisch)
  - Shift: verschiebe ein Wort auf den Stapel (Stack)
  - Reduce: wende eine passende Regel auf die obersten Elemente des Stapels an.

Shift

- Shift verschiebt ein Symbol auf den Stapel
- Konfiguration:
  - $\langle [A_1, \ldots, A_k], [w_i, w_{i+1}, \ldots, w_n] \rangle$
- Neue Konfiguration:
  - $\langle [A_1, \ldots, A_k, w_i], [w_{i+1}, \ldots, w_n] \rangle$

Reduce

- Reduce ersetzt die obersten Symbole des Stapels durch die linke Seite einer passenden Regel.
- Konfiguration:
  - $\langle [A_1, \ldots, A_{j-1}, A_j, \ldots, A_k], [w_i, \ldots, w_n] \rangle$
- Regel:
  - $B \rightarrow A_j, \ldots, A_k$
- Neue Konfiguration:
  - $\langle [A_1, \ldots, A_{j-1}, B], [w_i, \ldots, w_n] \rangle$

Nichtdeterminismus

- Wie entscheiden wir, ob eine Shift oder eine Reduce-Operation angewendet werden soll?
  - Für bestimmte (eindeutige) Grammatiken: vorberechnete Aktions/Sprung-Tabellen.
  - Im Allgemeinen Fall: Suche & Backtracking

Implementierung in Python

```
rules = [ ( 'S', ['NP', 'VP']), ('NP', ['D', 'N']), ... ]
def shift(stack, sntnc):
    return ([sntnc[0]] + stack, sntnc[1:])
def rdce(stack, sntnc, lhs, rhs):
    return ([lhs] + stack[len(rhs):], sntnc)
def matches(stack, rhs):
    if len(stack) < len(rhs):
        return False
    for (s, r) in zip(stack, reversed(rhs)):
        if s != r:
            return False
    return True
```


Implementierung in Python

```
def recognize(sntnc):
    agenda = [([], sntnc)]
    while agenda:
        (stack, sntnc) = agenda.pop()
        if sntnc == [] and stack == ['S']:
            return True
        if sntnc != []:
            agenda.append(shift(stack, sntnc))
        for (lhs, rhs) in rules:
            if matches(stack, rhs):
                agenda.append(rdce(stack, sntnc, lhs, rhs))
    return False
```

Problematische Regeln

- Reine Bottom-up Verfahren können nicht ohne Weiteres mit bestimmten Grammatiken verwendet werden.
  - Parser terminiert ggf. nicht
- Regeln der Form $A \rightarrow \varepsilon$
  - $\langle [A_1, \ldots, A_k], [w_i, \ldots, w_n] \rangle$
  - $\langle [A_1, \ldots, A_k, A], [w_i, \ldots, w_n] \rangle$ (reduce)
  - $\langle [A_1, \ldots, A_k, A, A], [w_i, \ldots, w_n] \rangle$ (reduce)
  - […]

Problematische Regeln

- Reine Bottom-up Verfahren können nicht ohne Weiteres mit bestimmten Grammatiken verwendet werden.
  - Parser terminiert ggf. nicht
- Zyklische Regeln: $A \rightarrow B$, $B \rightarrow A$
  - $\langle [A_1, \ldots, A_k, A], [w_i, \ldots, w_n] \rangle$
  - $\langle [A_1, \ldots, A_k, B], [w_i, \ldots, w_n] \rangle$ (reduce)
  - $\langle [A_1, \ldots, A_k, A], [w_i, \ldots, w_n] \rangle$ (reduce)
  - $\langle [A_1, \ldots, A_k, B], [w_i, \ldots, w_n] \rangle$ (reduce)
  - […]

Top-Down Parsing

- Initiale Konfiguration für Eingabekette $w_1 \ldots w_n$
  - $\langle [S], [w_1, \ldots, w_n] \rangle$
- Akzeptierende Konfiguration:
  - $\langle [], [] \rangle$
- Operationen:
  - Predict: Anwendung einer Regel auf das linkeste Nicht-terminalsymbol.
  - Scan: Eingabe konsumieren

Top-Down Parsing: Predict

- Konfiguration:
  - $\langle [A_1, A_2, \ldots, A_k], [w_i, \ldots, w_n] \rangle$
- Regel:
  - $A_1 \rightarrow B_1 \ldots B_m$
- Neue Konfiguration:
  - $\langle [B_1, \ldots, B_m, A_2, \ldots, A_k], [w_i, \ldots, w_n] \rangle$

Top-Down Parsing: Scan

- Konfiguration:
  - $\langle [w_i, A_1, \ldots, A_k], [w_i, w_{i+1}, \ldots, w_n] \rangle$
- Neue Konfiguration:
  - $\langle [A_2, \ldots, A_k], [w_{i+1}, \ldots, w_n] \rangle$

Problematische Regeln (Top-Down)

- Links- bzw. Rechtsrekursive Regeln – abhängig davon, ob die Eingabe von rechts nach links oder umgekehrt abgearbeitet wird.
  - NP → DET N, DET → NP ’s
  - S → S CONJ S

Übungsaufgabe 1

- Implementiere eine Klasse für Parsebäume …
- und erweitere den Beispielcode des Shift-Reduce Erkenners zu einem Parser.
- Hinweis: Speicher Parsebäume statt Nichtterminalsymbole auf dem Stack.

Übungsaufgabe 2

- Implementiere den Shift-Reduce Parser als Iterator, der alle Ableitungsbäume aufzählt
- for tree in parse(['der', 'student', ...]): dosomething(tree)

Übungsaufgabe 3

- Implementiere einen Top-Down Erkenner.
- Beachte: Es ist sinnvoll, zwischen „eigentlichen“ Regeln und Lexikoneinträgen (A → a) zu unterscheiden. Warum?
  - Der Algorithmus muss dann leicht modifiziert werden.
- Bonus: Parser statt Erkenner (kniffelig)