LMU LUDWIG-MAXIMILIANS-UNIVERSITÄT MÜNCHEN

Einführung in die Informatik:
Programmierung und Softwareentwicklung
Wintersemester 2018/19

Kapitel 2: Methoden zur Beschreibung von Syntax

Prof. Dr. David Sabel

Lehr- und Forschungseinheit für Theoretische Informatik

Institut für Informatik, LMU München

WS 2018/19

Stand der Folien: 26. Oktober 2018

Die Inhalte dieser Folien basieren – mit freundlicher Genehmigung – tlw. auf Folien von Prof. Dr. Rolf Hennicker aus dem WS 2017/18 und auf Folien von PD Dr. Ulrich Schöpp aus dem WS 2010/11

Übersicht: Inhalt und Ziele

Zwei Methoden zur Beschreibung (Definition) der **Syntax von Programmiersprachen**

- Backus-Naur-Form **BNF** und deren Erweiterung **EBNF**
- Syntax-Diagramme

Peter Naur
1928-2016
Mitwirkung bei ALGOL 60
2005 ACM Turing Award

John Backus
1924-2007
Entwicklung von FORTRAN
1977 ACM Turing Award

Bildnachweise: (1) The original uploader was Eriktj at English Wikipedia. (https://commons.wikimedia.org/wiki/File:Peternaur.JPG), Peternaur, https://creativecommons.org/licenses/by-sa/3.0/legalcode
(2) Pierre.Lescanne (https://commons.wikimedia.org/wiki/File:John_Backus.jpg), https://creativecommons.org/licenses/by-sa/4.0/legalcode

Aufbau von Programmen

- Java-Programme lassen sich ähnlich wie natürlichsprachliche Texte in verschiedenartige Einzelteile zerlegen
- Natürliche Sprache

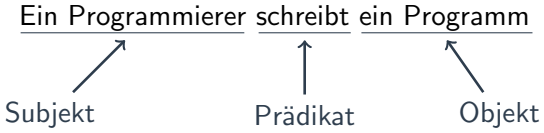

- Java-Programm

```
public class Test {
  public static void main(String[] args){
    System.out.print("Hal");
    System.out.println("lo!");
  }
}
```

Anweisungen

Methoden-definition

Methodenname

Stringliteral

Syntax von Programmiersprachen

- Der Aufbau von Programmen ist durch die Syntax der Programmiersprache festgelegt.
- Syntax einer Programmiersprache:

  System von Regeln, das festlegt,
  - aus welchen Einzelteilen Programme bestehen können,
  - wie man diese Einzelteile textuell aufschreibt und
  - wie man sie zu einem Programm kombinieren kann.
- Unterschied zu natürlicher Sprache:
  Die Syntax von Programmiersprachen ist vollständig und präzise festgelegt.

Syntax von Programmiersprachen (2)

- Seit ALGOL 60 wird die Syntax von Programmiersprachen präzise durch formale Grammatiken beschrieben.

  Der Compiler benutzt die Grammatik der Programmiersprache, um ein gegebenes Programm auf Richtigkeit zu überprüfen.
- Die Compiler-Phase, in der das geschieht, nennt man Syntaxanalyse oder Parsen.
- Im Fehlerfall tritt ein „Syntax Error“ (auch „Parse Error“ genannt) auf.

BNF und Syntaxdiagramme: Grundideen

Beispiel für eine Grammatikregel:

- Als Syntaxdiagramm:

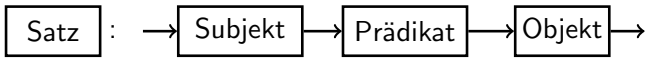

- In BNF-Form:

  <Satz> ::= <Subjekt> <Prädikat> <Objekt>
- In EBNF-Form:

  Satz = Subjekt Prädikat Objekt

Das Syntaxdiagramm und die (E)BNF (Backus-Naur-Form) erlauben das Bilden syntaktisch korrekter Sätze:

- `Ein Programmierer schreibt ein Programm`

  `Ein Programmierer` ← Subjekt
  `schreibt` ← Prädikat
  `ein Programm` ← Objekt

BNF und Syntaxdiagramme: Grundideen (2)

Weiterer Beispielsatz:

- `Ein Programm schreibt einen Programmierer`

  `Ein Programm` ← Subjekt
  `schreibt` ← Prädikat
  `einen Programmierer` ← Objekt

  Dieser Satz ist zwar **semantischer Unsinn**, aber **syntaktisch korrekt**.

Der Compiler benutzt die Grammatik um ein gegebenes Programm auf **syntaktische** Richtigkeit zu überprüfen

Backus-Naur-Form

- Die Backus-Naur-Form (BNF) wurde erstmals zur Beschreibung der Syntax von Algol 60 verwendet.
- Die BNF ist eine Notation für Grammatiken, die vor allem für die Beschreibung von Programmiersprachen verwendet wird.
- Heute ist die BNF (in notationellen Varianten) die Standardbeschreibungstechnik für Programmiersprachen und andere strukturierte Texte.
- Wir verwenden in der Vorlesung die „Erweiterte Backus-Naur-Form“ (EBNF) (eingeführt zur Beschreibung von PL1, 60er Jahre).
- Auch die Syntax von Java ist in einer Variante der Backus-Naur-Form beschrieben.
- Wichtige Begriffe: Symbole, Regeln, Grammatik, Ableitung

Symbole

In Grammatiken (BNF / EBNF) kommen drei Arten von Symbolen vor:

- Nichtterminalsymbole
- Terminalsymbole
- Operatorsymbole

Symbole: Nichtterminale

Nichtterminalsymbole:

Symbole, **die noch ersetzt werden**, und daher durch **Regeln** definiert werden.

- In der BNF werden Nichtterminalsymbole gekennzeichnet, indem sie durch $< \ldots >$ umschlossen werden.
- In der EBNF gibt es keine besondere Kennzeichnung der Nichtterminalsymbole.

Beispiele:

- in BNF: <Digit>, <Sign>
- in EBNF: Digit , Sign

Symbole: Terminale

Terminalsymbole:

Zeichen oder Folgen von Zeichen, die **genau so** in der zu definierenden Sprache **vorkommen**.

- In der BNF werden Terminalsymbole nicht gekennzeichnet.
- In der EBNF werden Terminalsymbole gekennzeichnet, indem sie durch doppelte Anführungszeichen umschlossen werden.

Beispiele:

- in BNF: `0`, `1`, `class`
- in EBNF: `"0"`, `"1"`, `"class"`

Operatoren

Operatorsymbole:

- In der **BNF** gibt es
  - das Operatorsymbol **|** für den Auswahloperator
- In der **EBNF** gibt es:
  - Operatorsymbol **|** für den Auswahloperator
  - Operatorsymbol **[ ]** für den Optionsoperator
  - Operatorsymbol **{ }** für den Wiederholungsoperator

Regeln in EBNF

Jede **EBNF-Regel** (oder auch Produktion/Produktionsregel) hat die Form

Nichtterminalsymbol = *Ausdruck*

Ein *Ausdruck* ist entweder

- ein Terminalsymbol oder
- ein Nichtterminalsymbol oder
- ein **zusammengesetzter Ausdruck**.

Aus gegebenen Ausdrücken E, E_1 und E_2 können mit den Operatorsymbolen **zusammengesetzte Ausdrücke** gebildet werden:

- **Sequentielle Komposition** $E_1\,E_2$ („E_1 gefolgt von E_2“)
- **Auswahl** $E_1 \mid E_2$ („E_1 oder E_2“)
- **Option** $[E]$ („E darf weggelassen werden“)
- **Wiederholung** $\{E\}$
  („E kann 0-mal oder mehrmals hintereinander vorkommen“)

Grammatik und Worte

Eine **Grammatik** besteht aus

- einer Menge von Regeln für jedes Nichtterminal sowie
- einem Startsymbol (Nichtterminalsymbol)

Ein **Wort** ist eine Folge von Terminalzeichen.

Eine Grammatik G definiert eine Menge von Worten,
genannt: **Die Sprache von** G (Definition folgt noch)

Beispiele für EBNF-Grammatiken (1)

Grammatik für Ziffern (mit Startsymbol Digit)

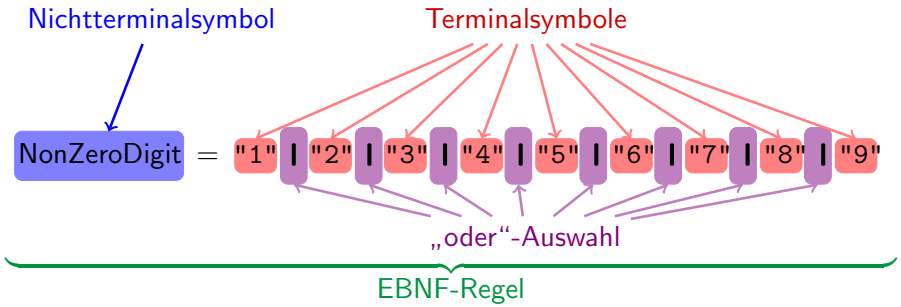

Digit = "0" | NonZeroDigit

Beispiele für EBNF-Grammatiken (2)

Grammatik für **ganze Zahlen**, wobei IntegerValue das Startsymbol ist:

IntegerValue	=	[Sign] DecimalNumeral
Sign	=	"+" | "−"
DecimalNumeral	=	"0" | NonZeroDigit [Digits]
Digits	=	Digit { Digit }

Informell: Eine ganze Zahl besteht aus einer nichtleeren Folge von Ziffern ohne führende Null, eventuell mit vorangestelltem Vorzeichen.

Andere mögliche Varianten für die Regel für Digits ohne den Wiederholungsoperator zu verwenden: (alle verwenden **Rekursion**):

- Digits = Digit [Digits] oder Digits = [Digits] Digit
- Ohne Optionsoperator:
  Digits = Digit | Digit Digits oder Digits = Digit | Digits Digit

Wie wendet man Regeln an?

Ist +42 eine ganze Zahl?

Wir bilden folgende Ableitung:

IntegerValue

→ Regel für IntegerValue: [Sign] DecimalNumeral

→ Ausführen des Operators [ ]: Sign DecimalNumeral

→ Regel für Sign: ("+" | "−") DecimalNumeral

→ Ausführen des Operators |: "+" DecimalNumeral

→ Regel für DecimalNumeral: "+" ("0" | NonZeroDigit [Digits])

→ Ausführen des Operators |: "+" NonZeroDigit [Digits]

→ Regel für NonZeroDigit: "+" ("1" | "2" | "3" | "4" | "5" | "6" | "7" | "8" | "9")[Digits]

→ Ausführen des Operators |: "+" "4" [Digits]

Wie wendet man Regeln an? (2)

"+" "4" [Digits]

→ Ausführen des Operators [ ]: "+" "4" Digits

→ Regel für Digits: "+" "4" Digit { Digit }

→ Regel für Digit: "+" "4" ("0" | NonZeroDigit){ Digit }

→ Ausführen des Operators |: "+" "4" NonZeroDigit { Digit }

→ Regel für NonZeroDigit: "+" "4" ("1"|"2"|"3"|"4"|"5"|"6"|"7"|"8"|"9"){ Digit })

→ Ausführen des Operators |: "+" "4" "2" { Digit }

→ Ausführen des Operators { }: "+" "4" "2"

Ableitung von Worten

Ein Wort w kann vom Startsymbol der Grammatik G **abgeleitet** werden, falls es eine **Ableitung** der Form $E_0 \to E_1 \to \ldots \to E_k$ gibt, wobei

- E_0 ist das Startsymbol der Grammatik G
- E_k ist identisch zum Wort w
- $E_i \to E_{i+1}$ entsteht entweder durch
  1. Ersetzung eines oder mehrerer Nichtterminale in E_i durch die rechte Seite ihrer Regeln, oder
  2. durch Ausführung von (einem oder mehreren) Operator(en), d.h.
     - $[E]$ darf gelöscht werden oder durch E ersetzt werden
     - $E \mid F$ darf durch E oder durch F ersetzt werden
     - $\{E\}$ darf gelöscht werden oder durch $E\{E\}$ ersetzt werden.

Kurze Ableitung

Häufig wird Schritt 1) und Schritt 2) in einem Schritt zusammengefasst. Man spricht dann von einer **kurzen Ableitung**.

- $E_i \to E_{i+1}$ entsteht durch
  1. Ersetzung eines oder mehrerer Nichtterminale in E_i durch die rechte Seite ihrer Regeln, und / oder
  2. durch Ausführung von (einem oder mehreren) Operator(en)

  sodass mindestens ein Nichtterminal ersetzt oder ein Operator ausgeführt wurde.

„Darf“-Konvention: Bei einer kurzen Ableitung dürfen Schritt 1) und 2) zusammengefasst werden (müssen aber nicht).

Folgerung: Jede lange Ableitung ist auch eine kurze
(Die Umkehrung gilt nicht!)

Beispiele (1)

Betrachte die folgende Grammatik mit Startsymbol PEx:

```
PEx         = NonZeroDigit | PEx "+" PEx
NonZeroDigit = "1" | "2" | "3" | "4" | "5" | "6" | "7" | "8" | "9"
```

Eine (lange) Ableitung von 1+2+3:

PEx

→ (Ersetzung von PEx)
NonZeroDigit | PEx "+" PEx

→ (Ersetzung von PEx)
NonZeroDigit | PEx "+" (NonZeroDigit | PEx "+" PEx)

→ (Ausführung von | (an 2 Stellen))
PEx "+" (PEx "+" PEx)

→ (Ersetzung von PEx (an 2 Vorkommen))
(NonZeroDigit | PEx "+" PEx) "+" (PEx "+" (NonZeroDigit | PEx "+" PEx))

→ (Ausführung von | (an 2 Stellen))
NonZeroDigit "+" (PEx "+" NonZeroDigit)

Beispiele (2)

```
PEx         = NonZeroDigit | PEx "+" PEx
NonZeroDigit = "1" | "2" | "3" | "4" | "5" | "6" | "7" | "8" | "9"
```

Fortsetzung der (langen) Ableitung von 1+2+3:

NonZeroDigit "+" (PEx "+" NonZeroDigit)

→ (Ersetzung von NonZeroDigit (2×) und PEx)
("1" | ... | "9") "+" ((NonZeroDigit | PEx "+" PEx) "+" ("1" | ... | "9"))

→ (Ausführung von | (mehrere Stellen))
"1" "+" NonZeroDigit "+" "3"

→ (Ersetzung von NonZeroDigit)
"1" "+" ("1" | ... | "9") "+" "3"

→ (Ausführung von |)
"1" "+" "2" "+" "3"

Beispiele (3)

```
PEx         = NonZeroDigit | PEx "+" PEx
NonZeroDigit = "1" | "2" | "3" | "4" | "5" | "6" | "7" | "8" | "9"
```

Eine kurze Ableitung von 1+2+3:

PEx

→ (Ersetzung von PEx und Ausführung von |)
PEx "+" PEx

→ (Ersetzung von PEx (2×) und Ausführung von | (2×))
NonZeroDigit "+" PEx "+" PEx

→ (Ersetzung von NonZeroDigit und PEx (2×) Ausführung von | (mehrfach))
"1" "+" NonZeroDigit "+" NonZeroDigit

→ (Ersetzung von NonZeroDigit (2×) und Ausführung von | (mehrfach))
"1" "+" "2" "+" "3"

Die Sprache einer Grammatik

Jede Grammatik G definiert eine Menge von Wörtern, die als **Sprache von** G bezeichnet wird.

- Wir schreiben $L(G)$ für die Sprache von G. (L steht für Language.)
- Die Sprache $L(G)$ besteht genau aus den Wörtern, die vom Startsymbol der Grammatik **abgeleitet** werden können:

$$L(G) = \{w \mid S \to \ldots \to w,\ S \text{ Startsymbol von } G,\ w \text{ ein Wort}\}$$

Beispiele

Sei G die folgende Grammatik mit Startsymbol Start:

Start = "a" Mitte "c"
Mitte = { "b" }

$L(G)$ = Menge aller Worte, die mit a anfangen,
dann beliebig viele b's folgen und schließlich mit c enden

Beispiele

Sei G die folgende Grammatik mit Startsymbol Brackets:

Brackets = Brackets Brackets
| "(" ")"
| "[" "]"
| "(" Brackets ")"
| "[" Brackets "]"

$L(G)$ = Menge aller korrekt geklammerten Klammerausdrücke
aus runden und eckigen Klammern

EBNF-Grammatik für Bezeichner

- Ein **Bezeichner** (Identifier) ist eine nichtleere Folge von Buchstaben oder Ziffern, beginnend mit einem Buchstaben.
- Bezeichner sind z.B. A, A200D3, Muenchen
- Keine Bezeichner sind $007, O.K., 1A$
- EBNF-Grammatik (mit Startsymbol Identifier)

Letter = "A" | ... | "Z" | "a" | ... "z"
Identifier = Letter { Letter | Digit }
Digit = ... (wie vorher)

- In Java müssen alle Variablennamen, Klassennamen usw. Bezeichner sein. Die Grammatik in Java ist jedoch etwas allgemeiner als oben

EBNF-Variante für Java

- Die Java-Sprachdefinition verwendet eine andere Variante der EBNF.
https://docs.oracle.com/javase/specs/jls/se8/html/jls-2.html#jls-2.4

Notation dort:

- Nichtterminalsymbole sind *kursiv*
- Terminalsymbole sind in `Schreibmaschinenschrift`
(z.B. `if` statt `"if"`)
- Regeln werden als $N : E$ (anstelle von $N = E$) geschrieben
- Das Auswahlsymbol, d.h. | wird weggelassen und durch einen Zeilenumbruch ersetzt, oder man verwendet (one of)
- In **älteren** Spezifikationen: Die Option wird durch tiefgestelltes opt gekennzeichnet: E_{opt} statt $[E]$.

Beispiele aus der Java-Spezifikation

DecimalNumeral :
0
NonZeroDigit [*Digits*]

Digits :
Digit
Digits Digit

Digit :
0
NonZeroDigit

NonZeroDigit :
(one of)
1 2 3 4 5 6 7 8 9

Syntaxdiagramme

Ein Syntaxdiagramm ist ein einfacher grafischer Formalismus zur Definition von Sprachen. Er besteht aus

- Rechtecken, in denen Nichtterminale stehen
- Ovalen (oder Rechtecke mit abgerundeten Ecken) in den Terminale stehen
- Pfeilen, die die Elemente verbinden,
- Genau einem Eingangs- und einem Ausgangspfeil
- Je ein Nichtterminalsymbol wird durch je ein Syntaxdiagramm definiert

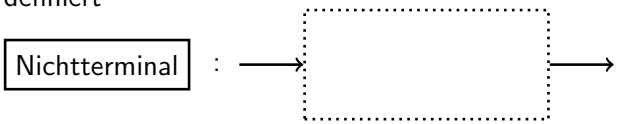

Beispiele für Syntaxdiagramme

EBNF:

Satz = Subjekt Prädikat Objekt

Syntax-Diagramm:

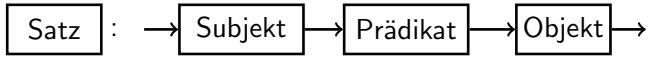

(Syntaxdiagramme für Subjekt, Prädikat, Objekt müssen noch hinzugefügt werden)

Beispiele für Syntaxdiagramme (2)

EBNF:

Digit = "0" | "1" | "2" | ... | "9"
Digits = Digit [Digits]

Syntaxdiagramm:

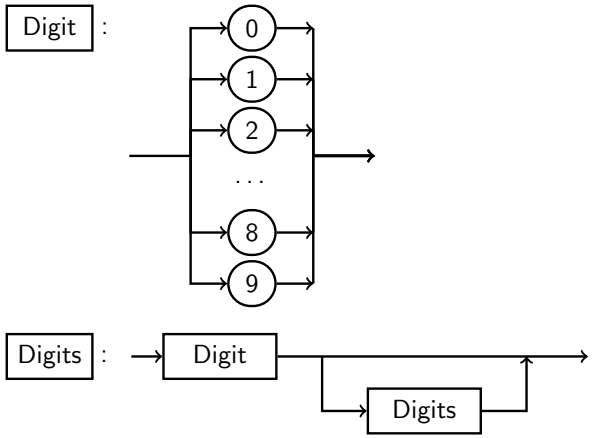

Vom Syntaxdiagramm definierte Sprache

Ein Wort w liegt genau dann, in der durch ein Syntaxdiagramm definierten Sprache, wenn man das Syntaxdiagramm vom Eingangs- zum Ausgangspfeil „entlang“ w durchlaufen kann:

- Alle durchlaufenen Knoten (T) für Terminalsymbole geben aneinander gereiht (in der Durchlaufreihenfolge) das Wort w.
- Durchlauf durch einen Knoten [N] für Nichtterminalsymbol N bedeutet Durchlauf des Syntaxdiagramms für N.
- Der durchlaufene Weg hat endliche Länge.

Beispiel

Wird 1019 durch das Synaxdiagramm für Digits erkannt?

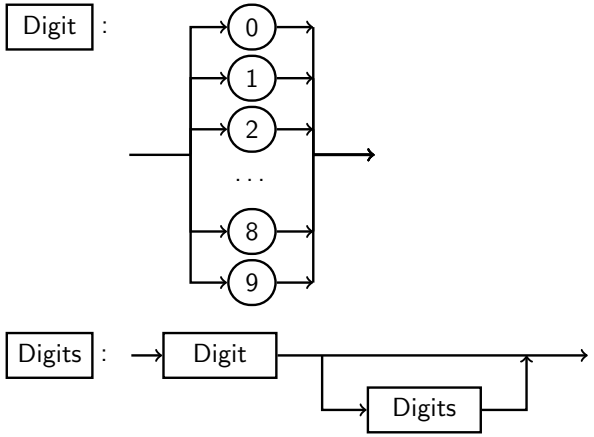

Noch ein Beispiel

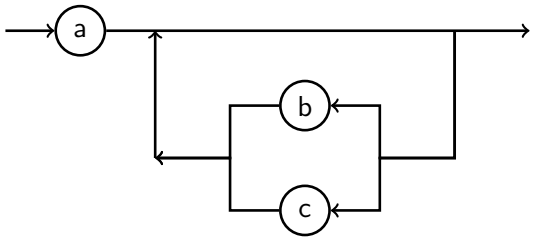

Welche Worte werden durch das Syntaxdiagramm erkannt?

- abbbbb ✓
- a ✓
- aabbcc ×
- abccb ✓
- bcbc ×
- bcabc ×

Allgemein: Alle Worte, die mit genauem einem a anfangen und anschließend beliebige b und c folgen dürfen.

EBNF dazu: N = "a" { "b" | "c" }

Korrespondenz von EBNF und Syntaxdiagrammen (1)

- **Auswahl** E_1 | E_2 wird durch eine Verzweigung repräsentiert:

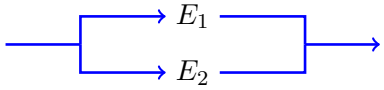

- **Sequentielle Komposition** E_1 E_2 wird durch Aneinanderhängen repräsentiert:

- **Option** $[E]$ wird repräsentiert durch:

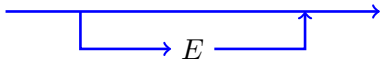

- **Wiederholung** $\{E\}$ wird repräsentiert durch:

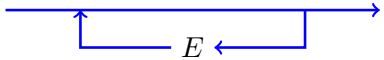

Korrespondenz von EBNF und Syntaxdiagrammen (2)

Umgekehrt geht es auch:

Jedes Syntaxdiagramm lässt sich als EBNF darstellen.

Folgerung

Syntaxdiagramme und EBNF sind äquivalent in dem Sinne, dass sie die gleiche Klasse von formalen Sprachen beschreiben.

Man nennt diese Klasse: Die **Kontextfreien Sprachen**

Der Begriff „kontextfrei“ rührt daher, dass Nichtterminale ersetzt werden, ohne benachbarte Symbole zu betrachten (den Kontext)

Formale Sprachen: Bemerkungen

- Die Informatik verwendet zur Klassifizierung von formalen Grammatiken häufig die sogenannte **Chomsky-Hierarchie** (benannt nach Noam Chomsky)

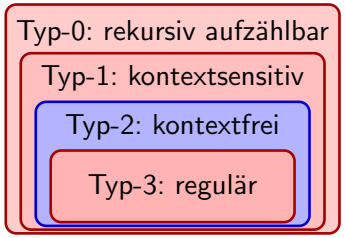

- Beispiel für eine formale Sprache die **nicht kontextfrei** ist:

  Die Sprache bestehend aus allen Wörtern der Form $a^n b^n c^n$ mit $n \geq 1$, d.h. die Wörter abc, aabbcc, aaabbbccc, aaaabbbbcccc, ...

Reguläre Sprachen

Reguläre Grammatiken haben nur Regeln der Form

$$E = F_1 \mid \ldots \mid F_n$$

wobei jedes der F_i von einer der folgenden Formen ist:

- w mit w ist ein Wort (d.h. Folge von Terminalsymbolen),
- wE' mit w ein Wort und E' ein Nichtterminalsymbol, oder
- ε (das leere Wort)

Die durch reguläre Grammatiken erzeugten Sprachen heißen **reguläre Sprachen**

Reguläre Grammatiken: Beispiele

Grammatik G_1 mit Startsymbol A:

A = "a" "a" | "a" "a" A

Die Grammatik G_1 ist regulär und $L(G_1)$ ist die Menge aller Worte mit gerader Anzahl an a's (mindestens 2).
Grammatik mit G_2 mit Startsymbol B:

B = "a" "a" | "a" B "a"

Die Grammatik ist **nicht regulär**, aber $L(G_2) = L(G_1)$.

Beachte: Die Sprache bestehend aus allen Worten mit einer geraden Anzahl an a's ist eine **reguläre Sprache**, da sie durch **eine** reguläre Grammatik erzeugt wird.

Reguläre Sprachen (3)

Reguläre Sprachen sind eine **echte Teilmenge** der kontextfreien Sprachen (d.h. der durch EBNFs erzeugten Sprachen).

Beispiel: Die Sprache aller Worte der Form $a^n b^n$ mit $n \geq 1$ ist nicht regulär, aber die EBNF

AnBn = "a" "b" | "a" AnBn "b"

erzeugt diese (d.h. die Sprache ist kontextfrei).

Beispiel: Palindrome

Ein **Palindrom** ist ein Wort das von links oder von rechts gelesen dasselbe Wort ergibt (griechisch palíndromos: „rückwärts laufend“)

Palindrome sind z.B.	**Keine Palindrome:**
"legeaneinebrandnarbenienaegel"	37687
ANNA	ANANAS
ANANA	ANNAN
A	ANAA
37873	

Syntaxdiagramm für Palindrome

Syntaxdiagramm für Palindrome, die mit den Buchstaben A und N gebildet werden können:

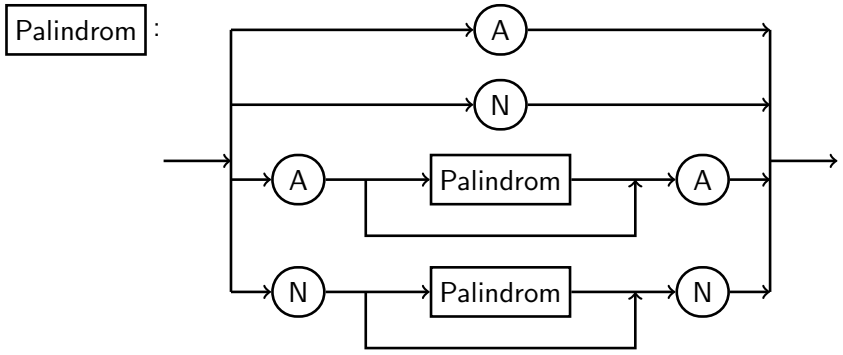

EBNF für Palindrome

EBNF-Grammatik für Palindrome, die mit den Buchstaben A und N gebildet werden können:

```
Palindrom = "A"
          | "N"
          | "A" [ Palindrom ] "A"
          | "N" [ Palindrom ] "N"
```

Zusammenfassung

- Formalismen zur Beschreibung der Syntax von Programmiersprachen
- Backus-Naur-Form (BNF)
- Erweiterte Backus-Naur-Form (EBNF)
  Jede (E)BNF-Grammatik besteht aus
  - einem Startsymbol und
  - einer Menge von Regeln (eine Regel pro Nichtterminalsymbol)
- Jede (E)BNF-Grammatik G erzeugt eine Sprache $L(G)$ (Menge von Wörtern)

Zusammenfassung (2)

- Syntaxdiagramme sind ein zu (E)BNF-äquivalenter grafischer Formalismus, wobei
  - Nichtterminalsymbole in Rechttecken
  - Terminalsymbole in Ovalen
  - Pfeile führen von einem Sprachelement zum anderen
  - jedes Syntaxdiagramm besitzt genau einen Eingangs- und Ausgangspfeil.
- All diese Formalismen repräsentieren die sogenannten kontextfreien Sprachen (vgl. Chomsky-Hierarchie)