Kapitel 2

Methoden zur Beschreibung von Syntax

„Grammatik,
die sogar Könige zu kontrollieren weiß ...“

– aus Molière, Les Femmes Savantes (1672), 2. Akt

Ziele

Zwei Standards zur Definition der Syntax von Programmiersprachen kennenlernen:

- Backus-Naur-Form (BNF)
  sowie deren Erweiterung EBNF
- Syntaxdiagramme

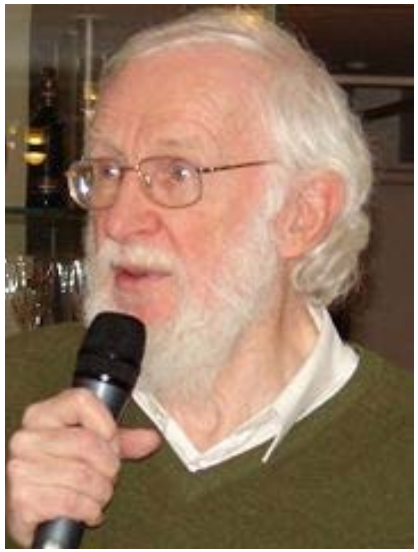

Peter Naur
*1928 – 2016
Mitwirkung bei ALGOL 60
Turingpreis 2005

John Backus
1924-2007
Entwicklung von FORTRAN
Turingpreis 1977

Syntax und Programme

- Java-Programme sind Texte, die sich wie natürlichsprachliche Texte in verschiedenartige Einzelteile zerlegen lassen.
- Natürliche Sprache:

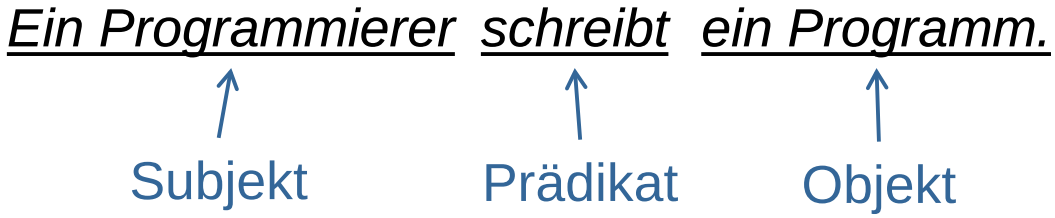

- Java-Programm:

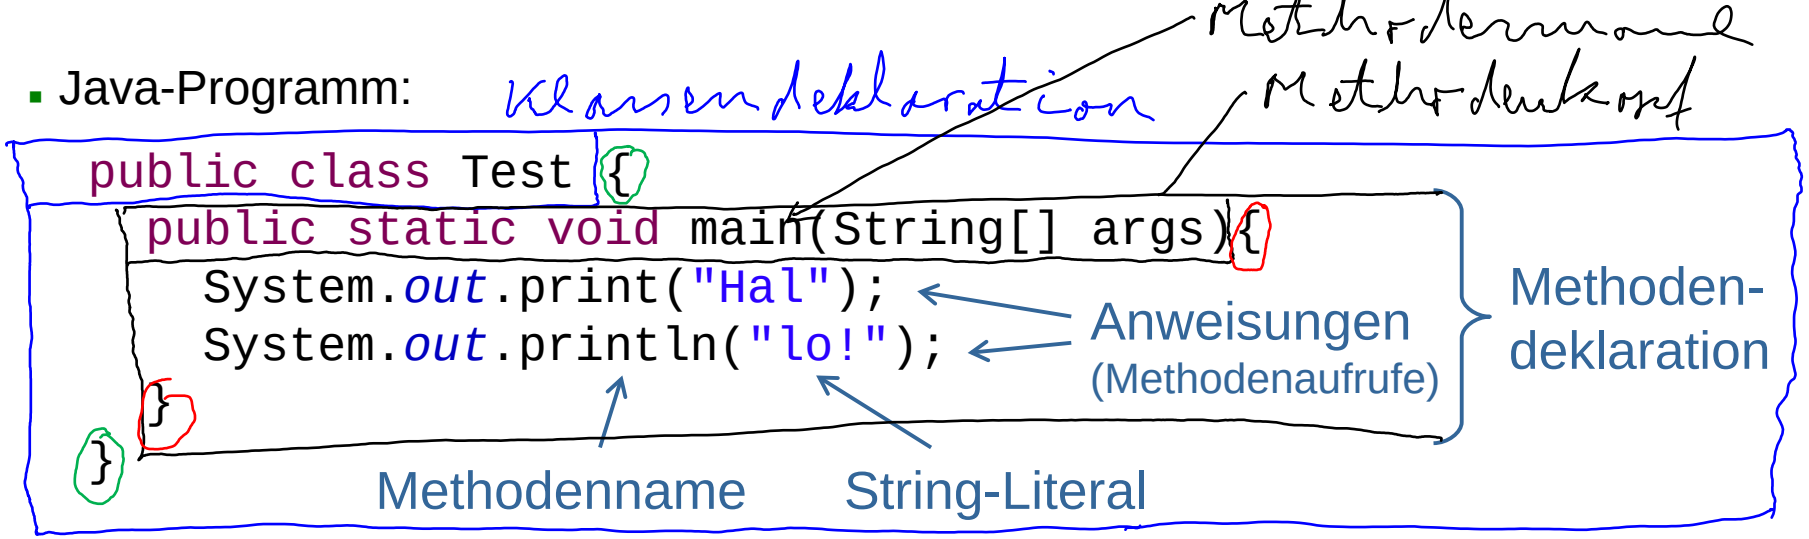

BNF und Syntaxdiagramme: Grundideen

- Beispiel für eine Grammatikregel:

Als Syntaxdiagramm:

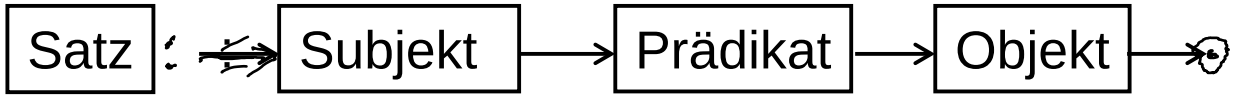

In BNF-Form: *<Satz> ::= <Subjekt> <Prädikat> <Objekt>.*

In EBNF-Form: *Satz = Subjekt Prädikat Objekt "."*

- Das Syntaxdiagramm und die BNF *(Backus-Naur-Form)* erlauben das Bilden folgender syntaktisch korrekter Sätze:
  - *Ein Programmierer schreibt ein Programm.*
    - *Ein Programmierer* — Subjekt
    - *schreibt* — Prädikat
    - *ein Programm* — Objekt
  - *Ein Programm schreibt einen Programmierer*

    Dieser Satz ist zwar semantischer Unsinn, aber syntaktisch korrekt.

- Der Compiler benützt 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 Standard-beschreibungstechnik 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

- **Nichtterminalsymbole:**

  Begriffe, die durch Regeln definiert werden.

  Beispiele

  in BNF: *<Digit>*, *<Sign>*

  in EBNF: *Digit*, *Sign*

- **Terminalsymbole:**

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

  Beispiele

  in BNF: `0`, `1`, `class`

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

- **Operatorsymbole:**

  in BNF: **|** für Auswahl

  in EBNF: **|** sowie **[ ]** für Optionen und **{ }** für Wiederholung

Regeln in EBNF

Jede **EBNF-Regel** hat die Form

Nichtterminalsymbol = Ausdruck

Ein Ausdruck ist entweder

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

Aus gegebenen Ausdrücken E, E1 und E2 können unter Verwendung der Operatorsymbole zusammengesetzte Ausdrücke gebildet werden:

Sequentielle Komposition	E1 E2	(„E1 gefolgt von E2“)
Auswahl	E1 | E2	(„E1 oder E2“)
Option	[E]	(„E kann weggelassen werden“)
Wiederholung	{E}	(„E kann 0-mal oder mehrmals hintereinander vorkommen“)

Grammatik

- Eine **Grammatik** besteht aus
  - einer Menge von **Regeln** für jedes Nichtterminal sowie
  - einem Startsymbol (Nichtterminalzeichen)
- Jede Grammatik G definiert eine **Menge von Wörtern**, die als **Sprache von G** bezeichnet wird.
  - Ein **Wort** ist eine Folge von Terminalzeichen.
  - Wir schreiben **L(G)** für die Sprache von G. (L für Language)
  - Die Sprache L(G) besteht genau aus den Wörtern, die vom Startsymbol der Grammatik **abgeleitet** werden können.

Beispiele für EBNF-Grammatiken (1)

- Grammatik für Ziffern (mit Starsymbol *Digit*)

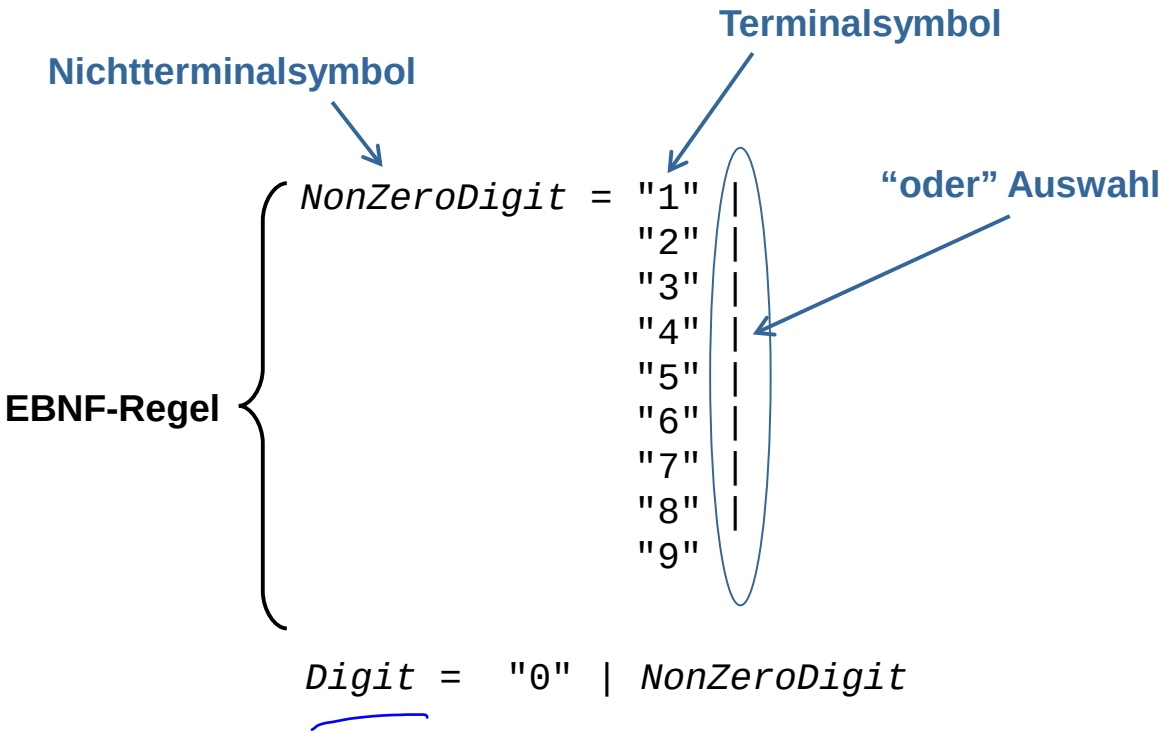

Beispiele für EBNF-Grammatiken (2)

- Grammatik für ganze Zahlen (Integers) mit Startsymbol *IntegerValue*
- Informelle Beschreibung: Eine ganze Zahl besteht aus einer nichtleeren Folge *von Ziffern* ohne führende „0“, evtl. mit einem vorangestellten Vorzeichen.
- Regeln:

```
IntegerValue = [Sign] DecimalNumeral

Sign = "+" | "-"

DecimalNumeral = "0" | NonZeroDigit [Digits]

Digits = Digit {Digit}
```

oder mit Rekursion: `Digits = Digit [Digits]`
oder
`Digits = [Digits] Digit`
oder
`Digits = Digit | Digits Digit`
oder `Digits = Digit | Digit Digits`

alle Regeln sind "gut"

Wie wendet man die Regeln an?

Ist +31 eine *GanzeZahl*?
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"| … |"9") [*Digits*]	→ (Ausführen des Operators |)
"+" "3" [*Digits*]	→ (Ausführen des Operators [ ])
"+" "3" *Digits*	→ (nicht rek. Regel für *Digits*)
"+" "3" *Digit* {*Digit*}	→ (Regel für *Digit*)
"+" "3" ("0"|*NonZeroDigit*) {*Digit*}	→ (Ausführen des Operators |)
"+" "3" *NonZeroDigit* {*Digit*}	→ (Regel für *NonZeroDigit*)
"+" "3" ("1"| … |"9") {*Digit*}	→ (Ausführen des Operators |)
"+" "3" "1"{*Digit*}	→ (Ausführen des Operators {})
"+" "3" "1"	

Ableitung von Worten

Ein Wort w kann vom Startsymbol der Grammatik abgeleitet werden (und ist dann in L(G)), falls es eine **Ableitung** der Form

$$E_0 \rightarrow E_1 \rightarrow \ldots \rightarrow E_k$$

gibt, wobei:

- E_0 das Startsymbol der Grammatik ist,
- E_k zum Wort w identisch ist,
- E_{i+1} aus E_i entsteht durch
  1) Ersetzung eines oder mehrerer Nichtterminale durch die rechte Seite ihrer Regeln oder durch
  2) Ausführung von Operatoren, d.h.
     - [*E*] darf durch *E* ersetzt oder gelöscht werden,
     - *E* | *F* darf durch *E* oder durch *F* ersetzt werden,
     - {*E*} darf gelöscht werden oder durch *E*{*E*} ersetzt werden.

Häufig wird Schritt 1) gefolgt von Schritt 2) in einem Schritt zusammengefasst. Man spricht dann von einer „kurzen Ableitung“.

EBNF-Grammatik für Bezeichner

Ein **Bezeichner** (*Identifier*) ist eine nichtleere Folge von Buchstaben oder Ziffern, beginnend mit einem Buchstaben.

Bezeichner sind z.B. A, A2D2, Passau
Keine Bezeichner sind 007, 1A, O.K. *(Punkte sind keine Buchstaben.)*

EBNF-Grammatik:

Letter = "A“|
"B“|
…
"Z"|
"a"|
…
"z"

Identifier = *Letter* {*Letter* | *Digit*}

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

BNF-Variante für Java

Bemerkung: Die Java-Spezifikation verwendet eine andere Variante der BNF.

- Nichtterminalsymbole *kursiv*
- Terminalsymbole Schreibmaschinenschrift (`if` statt `"if"`)
- Regeln N: E statt N = E
- Das Auswahlsymbol, d.h. | , wird weggelassen und durch neue Zeile ersetzt. Oder man verwendet *`one of`* .
- Die Option wird durch tiefgestelltes opt gekennzeichnet: E_{opt} statt [E]

Beispiele aus der Java-Spezifikation:

DecimalNumeral:
0
NonZeroDigit Digits$_{opt}$

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. Es besteht aus

- Rechtecken, in denen die Nichtterminale stehen,
- Ovalen, in denen die Terminale stehen,
- Pfeilen, die die Elemente verbinden,
- Eingangs- und Ausgangspfeilen

Beispiele für Syntaxdiagramme

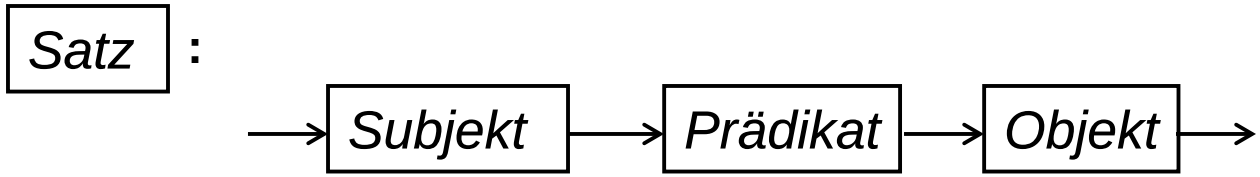

Beispiel:

```
Digit = "0" |
        "1" |
        "2" |
         …
        "9"
```

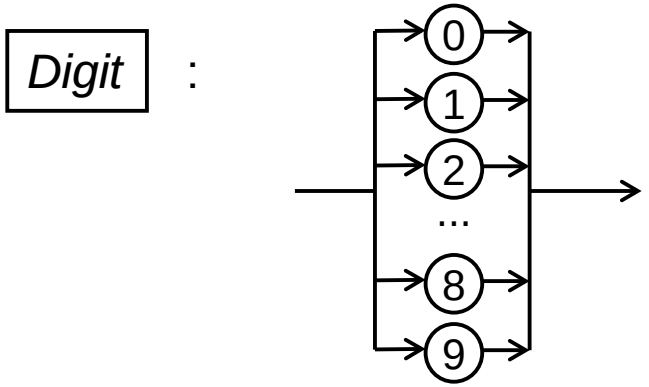

Beispiel:

```
Digits = Digit [Digits]
```

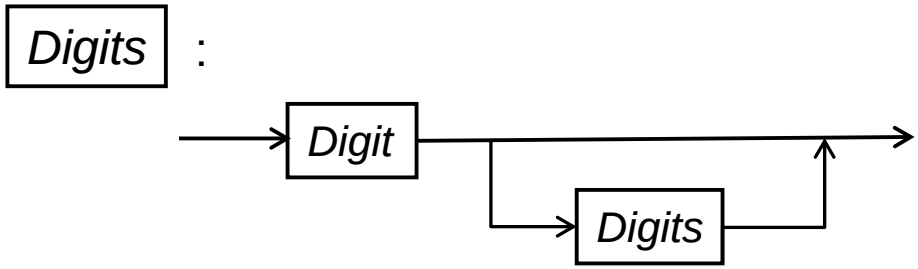

Korrespondenz von Syntaxdiagrammen und EBNF (1)

Jeder EBNF-Operator lässt sich durch ein Syntaxdiagramm ausdrücken:

- Auswahl: E1 | E2 wird repräsentiert durch eine Verzweigung.

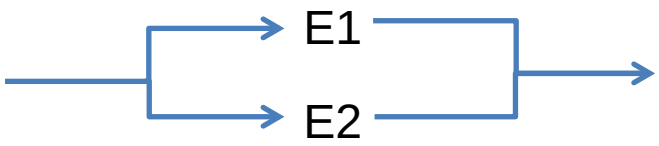

- Sequentielle Komposition: E1 E2 wird repräsentiert durch Aneinanderhängen

- Option: [E] wird repräsentiert durch

- Wiederholung: {E} wird repräsentiert durch

Korrespondenz von Syntaxdiagrammen und EBNF (2)

Umgekehrt lässt sich jedes Syntaxdiagramm durch eine EBNF-Grammatik ausdrücken.

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

Bemerkung:
Man nennt sie die Klasse der **kontextfreien Sprachen,** da Nichtterminalsymbole ohne Berücksichtigung ihrer benachbarten Symbole (d.h. ohne Berücksichtigung des Kontexts) durch Ausdrücke (nämlich durch die rechten Seiten der zugehörigen Regeln) ersetzt werden.

Beispiel für eine **nicht-kontextfreie** Sprache:
Die Sprache bestehend aus allen Wörtern der Form $a^n b^n c^n$ mit $n \geq 1$, d.h. alle Wörter der Form

abc, aabbcc, aaabbbccc, aaaabbbbcccc, ...

Beispiel: Palindrome

Ein **Palindrom** ist ein nichtleeres Wort, das von links wie von rechts gelesen das Gleiche ergibt.
(griechisch: Παλίνδρομος (*palíndromos*) „rückwärts laufend“ *[Wikipedia]*

Palindrome:	**Keine Palindrome:**
„lege an eine brandnarbe nie naegel“ (wenn man Leerzeichen ignoriert)	ANANAS
ANNA	ANAN
ANANA	ANAAA
NN	
A	
37873	37863

Syntaxdiagramm für Palindrome

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

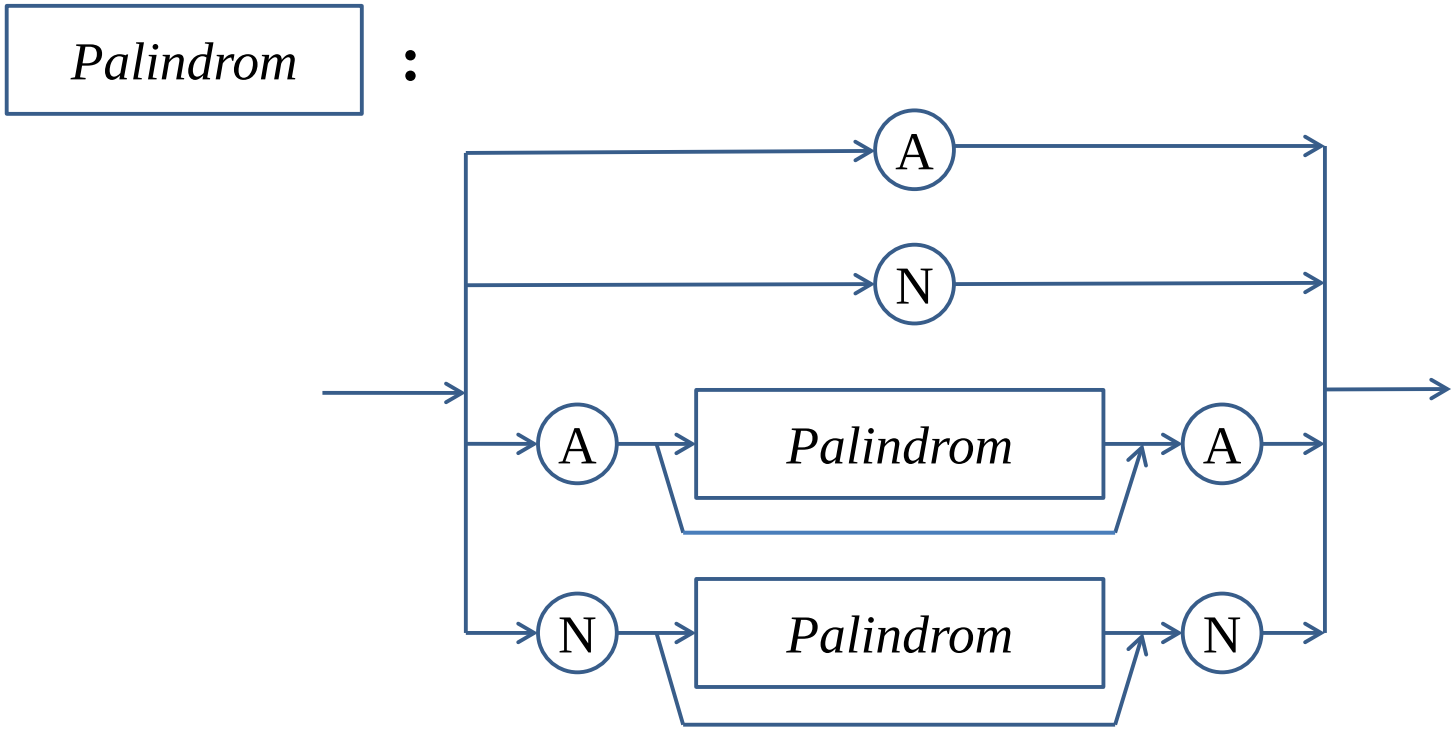

EBNF-Grammatik für Palindrome

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

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