Struktur des MicroJava-Compilers

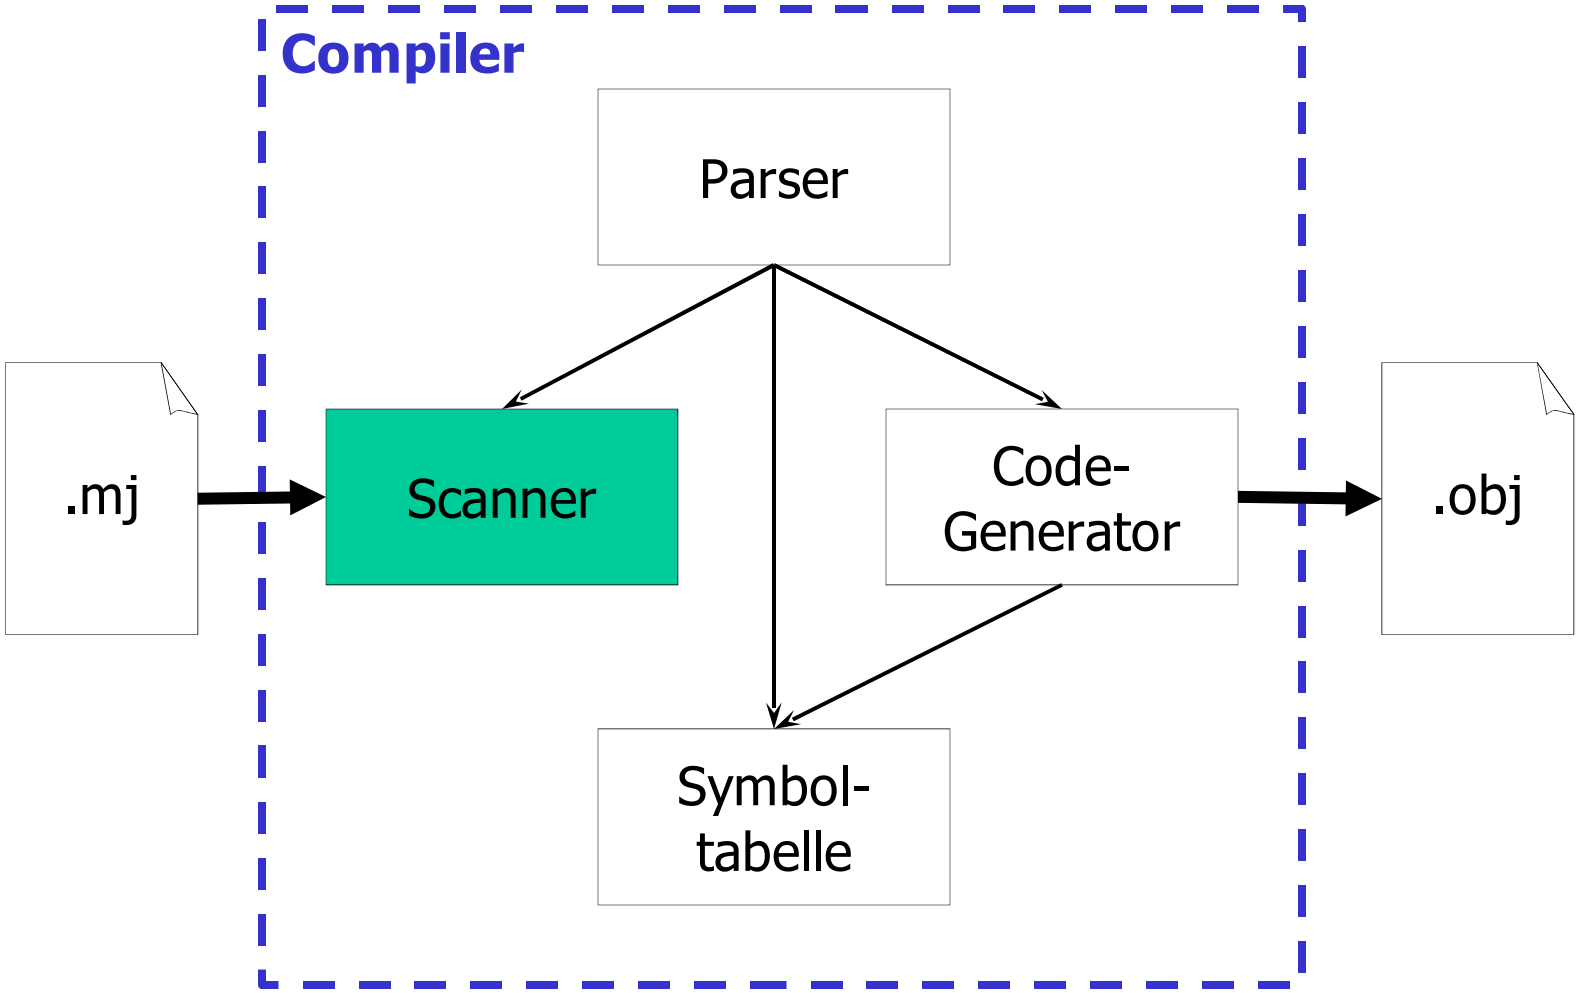

Grammatik ohne Scanner


```
Expr    = Term { "+" Term } .
Term    = Factor { "*" Factor } .
Factor  = ident .
```

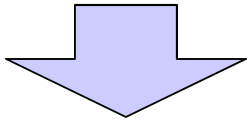

erlaube Kommentare an beliebiger Stelle

```
Expr    = [Comment] Term [Comment]
                { "+" [Comment] Term [Comment] } .
Term    = [Comment] Factor [Comment]
                { "*" [Comment] Factor [Comment] } .
Factor  = [Comment] ident [Comment] .
```

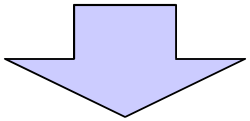

erlaube Whitespace an beliebiger Stelle

. . .

Klasse Token


```
class Token {
   int    kind;    // z.B. ident, assign, …
   int    line;    // Zeilenposition
   int    col;     // Spaltenposition
   int    val;     // numerischer Wert für number und charConst
   String string;  // Name von ident
}
```

Aufgaben des Scanners

- Erkennen von Terminalsymbolen
- Überlesen unbedeutender Zeichen (Blanks, Tabs, Zeilenumbrüche, ...)
- Überlesen von Kommentaren
- Erkennen von:
  - Namen
  - Schlüsselwortern
  - Zahlen
  - Zeichenkonsanten
  - Stringkonstanten (gibt es in *MicroJava* nicht)
- Bildung von Terminalklassen (ident, number, ...)
  int, char, null, eol, chr, ord, len sind keine Schlüsselwörter!
  nur vordeklarierte Namen (→ Erkennung als Name)
- Erkennen des Dateiendes
- lexikalische Fehler melden (Zahlenformat, ungültige Zeichen, ...)
- Einstellen der Scanner-Attribute der Tokens (Symbolart, Position, Wert, ...)

Scanner.next() (1)


```
public static Token next () {
    while (Character.isWhitespace(ch)) nextCh();  // skip white space

    Token t = new Token();
    t.line = line; t.col = col;                          // set position

    switch (ch) {
        //----- ident or keyword
        case 'a': case 'b': ... case 'z':
        case 'A': case 'B': ... case 'Z':
            readName(t);      // distinguish between identifier and keyword
            break;
        //----- number
        case '0': ... case '9':
            readNumber(t);
            break;
        . . .
```

Scanner.next() (2)


```
. . .
//----- character constant
 case '\'':
     t.kind = Token.charConst;
     nextCh();
     if (ch == '\'') { error ("empty character constant"); nextCh(); }
     else {
         if (ch >= ' ' && ch <= '~')          // printable chars
             t.val = (int) ch;
         else error("invalid character constant '" + ch + "'");
         nextCh();
         if (ch == '\'') nextCh();
         else error ("missing ' at end of character constant");
     }
     break;
. . .
```

Scanner.next() (3)


```
        . . .
        //----- simple tokens
        case ';': t.kind = Token.semicolon; nextCh(); break;      . . .
        case eofCh: t.kind = Token.endFile; /* no nextCh() ! */  break;
        //----- compound tokens
        case '=':
            nextCh();
            if (ch == '=') { t.kind = Token.eql; nextCh(); }
            else t.kind = Token.assign;
            break;
        case '/':
            nextCh();
            if (ch == '*') { skipComment(); t = next(); /* recursion! */  }
            else t.kind = Token.slash;
            break;
        . . .
    }
    if (t.kind = Token.none) error("invalid symbol");
    return t;
}
```

Scanner als endlicher Automat

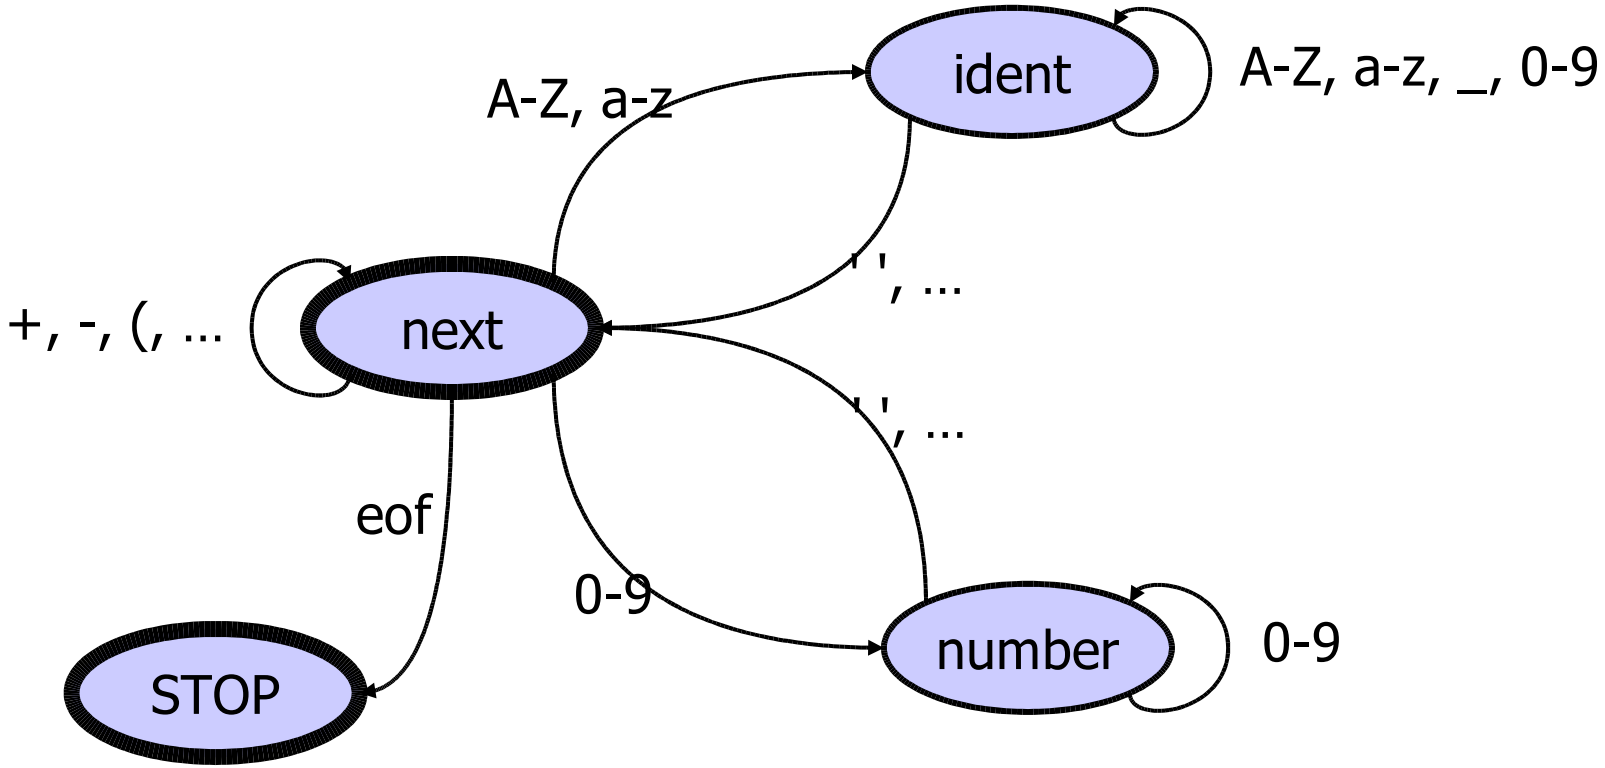

MicroJava

- eine einzige statische Klasse
- Hauptmethode void main () (kein Rückgabewert, keine Parameter)
- Typen: int (4 Byte), char (1 Byte, ASCII)
- globale und lokale Variablen, globale Konstanten
- eindimensionale Arrays
- Records (sehen aus wie innere Klassen)
- Methodenaufrufe sind *call-by-value* (Variablen sind aber Referenzen)
- Ein-/Ausgabe mit Hilfe der *read*- und *print*-Anweisung
- eingebaute Methoden ord(), chr(), len() und Konstanten null, eol
- keine Module, Importanweisungen, ...
- kein GC und auch kein delete (Objekte bleiben übrig – who cares ☺)
- keine for-Schleife, nur while- und do-while-Schleifen
- kein Ausnahmebehandlung (*exception handling*)
- keine Zeiger

UE 2: Lexikalische Analyse (Scanner)

- Testen
  - siehe Testanleitung auf Homepage!
  - nächste Woche in der UE:

    "Softwaretesten mit JUnit – eine Einführung" ☺
  - in UB-UE02-Angabe.zip:
    - Compilerklassen (Token.java, Gerüst von Scanner.java, ...)
    - Testklassen (AllTests.java, TokenTest.java, ScannerTest.java, ...)
    - Beispielkommando zum Übersetzen der Compiler- und Testklassen (in build.bat)
    - Beispielkommandos zum Ausführen der Tests (in test.bat + testGUI.bat)
- Abgabe
  - siehe Abgabeanleitung auf Homepage!
  - 2 Teile:
    - bis **Mi, 22.10.2003, 12:00** : elektronisch (via FTP)
    - bis Do, 30.10.2003, 8:15 : auf Papier & elektronisch (via FTP)