# Struktur des *MicroJava*-Compilers

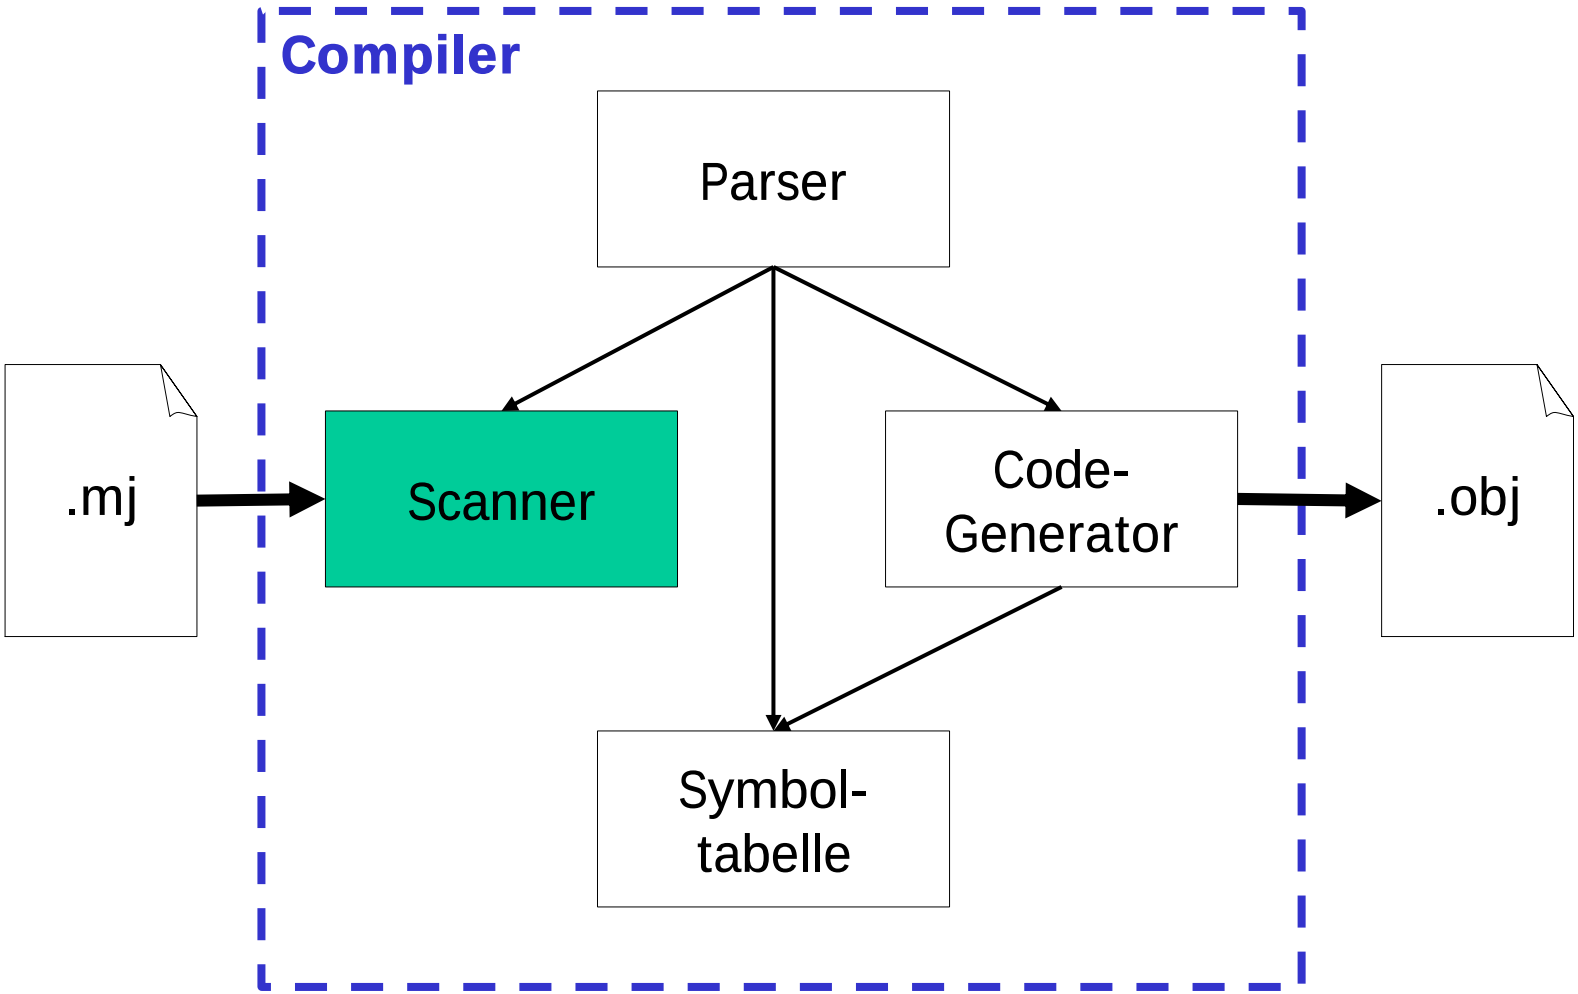

# Grammatik ohne Scanner


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

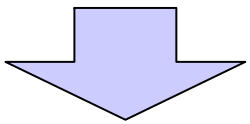

erlaube Kommentare an beliebiger Stelle

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

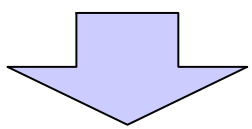

erlaube Whitespace an beliebiger Stelle

. . .

# Struktur des *MicroJava*-Compilers


- Package ssw.mj
  - Scanner.java + Token.java: Übung 2
  - Parser.java: Übung 3 (und alle weiteren Übungen)
  - Hilfsklassen für Fehlermeldungen
- Package ssw.mj.symtab
  - Verwaltung der Symboltabelle: Übung 4
- Package ssw.mj.codegen
  - Code-Generator: Übung 5 und Übung 6

- Diese Struktur darf nicht verändert werden
  - Keine zusätzlichen Klassen nötig
  - Bereits vollständig vorgegebene Klassen (= Klassen ohne TODO-Kommentar) nicht verändern

# Fehlermeldungen


- Klasse **Errors** sammelt alle Fehlermeldungen

  static void **error**(int line, int col, String msgKey, Object... msgParams);

- Fehlermeldungen sind in messages.properties definiert
  - Der error-Methode wird der Name der Meldung übergeben
    - Direkt als String im Quellcode
  - Manche Fehlermeldungen benötigen Parameter
    - Zusätzliche Parameter der error-Methode
  - Zugriff über die Klasse **Messages**

- Hilfsmethode im Scanner (später auch im Parser)

  static void **error**(Token t, String msgKey, Object... msgParams);
  - Übernimmt die Fehlerposition aus dem angegebenen Token

# Klasse Scanner + Token


```
class Scanner {
    public static void init(Reader r);
    public static Token next();
}

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

- Scanner wird (ab der 3. Übung) vom Parser aufgerufen
  - Jeder Aufruf von next() liefert das nächste Token
  - Scanner wartet, bis er aufgerufen wird

# Aufgaben des Scanners


- Erkennen von Terminalsymbolen
- Überlesen unbedeutender Zeichen (Blanks, Tabs, Zeilenumbrüche, ...)
- Überlesen von Kommentaren
- Erkennen von:
  - Namen
  - Schlüsselwörtern
  - Zahlen
  - Zeichenkonstanten
- Bildung von Terminalklassen (ident, number, ...)
  int, char, null, chr, ord, len sind keine Schlüsselwörter!
  nur vordeklarierte Namen (→ Erkennung als ident)
- Erkennen des Dateiendes
- lexikalische Fehler melden (Zahlenformat, ungültige Zeichen, ...)
- Einstellen der Token-Attribute (Symbolart, Position, Wert, ...)

# Scanner.next() (1)


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

    Token t = new Token(Token.none, line, col);

    switch (ch) {
        //----- identifier 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)


```
        . . .
        //----- simple tokens
        case ';': t.kind = Token.semicolon; nextCh(); break;
        case EOF: t.kind = Token.eof; /* 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); t = next(); /* recursion */ }
            else  . . . break;
        default:
            error(t, "INVALID_CHAR", ch); nextCh();
            break;
    }
    return t;
}
```

# Scanner als endlicher Automat

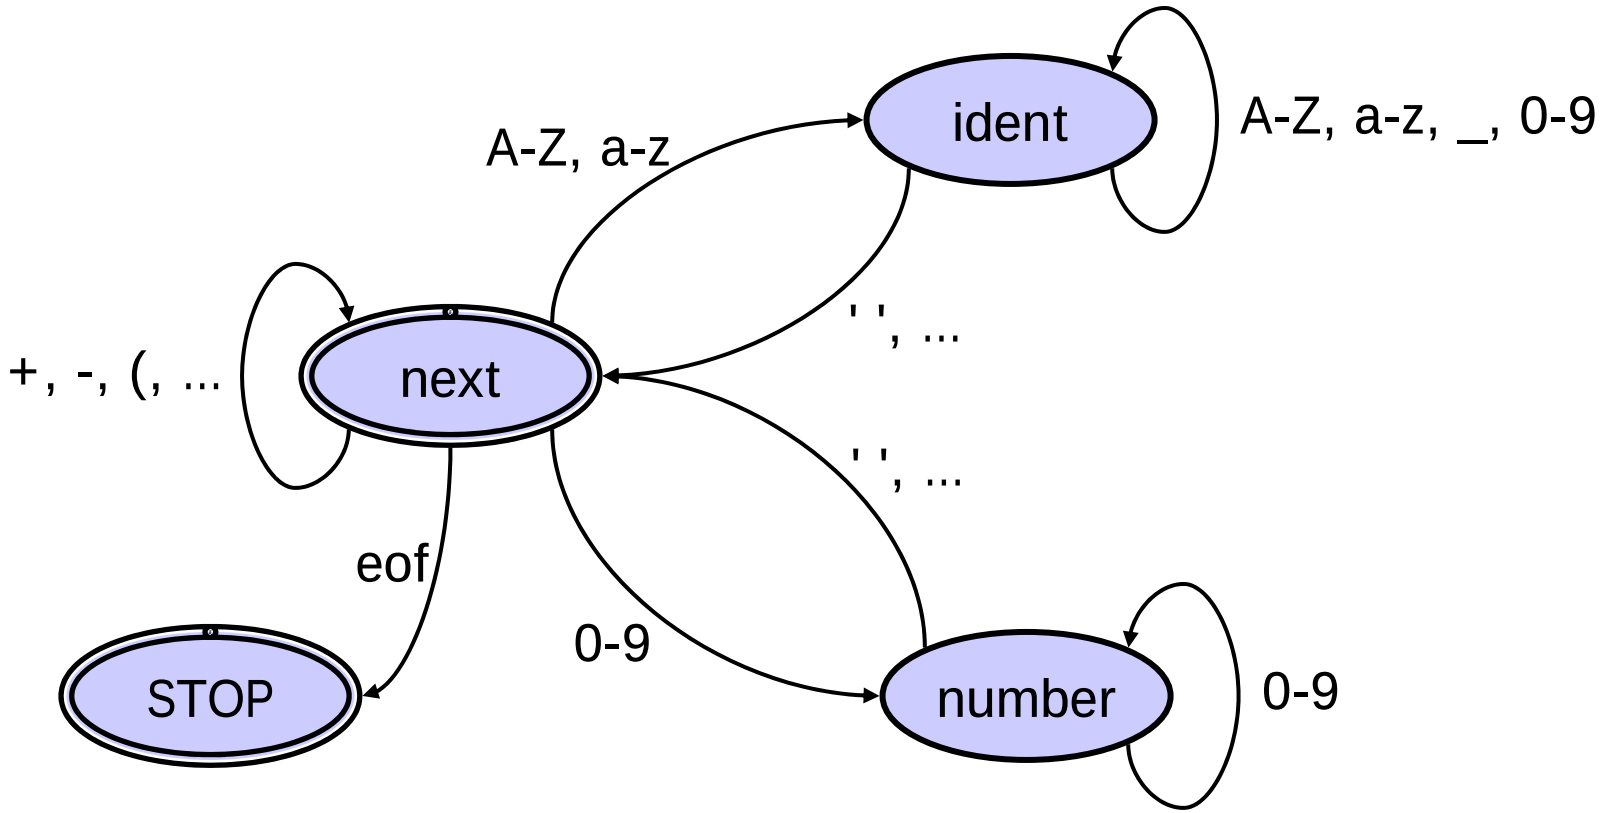

# Hilfsmethoden


- static void **nextCh**()
  - Liest das nächste Eingabezeichen und speichert es im Feld ch
    - oder EOF beim Dateiende
  - Führt die Position in den Feldern line und col mit
    - Erkennt Zeilenumbrüche: LF oder CR LF
- static void **readName**(Token t)
  - Liest einen Bezeichner
  - Erkennt Schlüsselwörter (Hashtabelle oder binäre Suche)
- static void **readNumber**(Token t)
  - Liest eine Zahlenkonstante
- static void **skipComment**(Token t)
  - Überliest geschachtelte Kommentare
  - ch enthält anschließend das Zeichen nach dem Kommentar

# Zahlen-Konstanten


- Gültige Zahlen
  - Normale Zahlen: `123`
    - Ein Token: *number*
  - Negative Zahlen: `-123`
    - Zwei Tokens: *minus* und *number*
  - Buchstaben: `123abc`
    - Zwei Tokens: *number* und *ident*
  - *Achtung:* `abc123`
    - Ein Token: *ident*

- Fehlerhafte Zahlen
  - Zu große Zahlen: `2147483648` error(t, "BIG_NUM");
  - Spezialfall: `-2147483648`

# Zeichen-Konstanten


- Gültige Zeichen-Konstanten
  - Normale Zeichen: `'A'`
  - Escape-Zeichen: `'\r'`, `'\n'`, `'\''` und `'\\'`

- Fehlerhafte Zeichen-Konstanten
  - Kein Zeichen: `''` error(t, "EMPTY_CHARCONST");
  - Fehlendes Ende: `'A` error(t, "MISSING_QUOTE");
  - Escape-Zeichen: `'\A'` error(t, "UNDEFINED_ESCAPE", ch);
  - Zeilenumbruch: `'¶` error(t, "ILLEGAL_LINE_END");

# Kommentare


- Nur Block-Kommentare
  - Scanner ignoriert alles zwischen /* und */
  - Kommentare können auch geschachtelt sein
    - /* a /* b */ c */
  - Methode skipComment() muss daher die Schachtelungstiefe mitführen

- Fehlerhafte Kommentare
  - Fehlendes Ende: /* ohne */ error(t, "EOF_IN_COMMENT");

# *MicroJava*


- eine einzige Quellcode-Datei
- 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)
- Parameterübergabe *call-by-value* (Objektparameter sind aber Referenzen)
- Ein-/Ausgabe mit Hilfe der *read*- und *print*-Anweisung
- eingebaute Methoden `ord()`, `chr()`, `len()` und Konstante `null`
- keine Packages und Importanweisungen, ...
- kein GC und auch kein `delete` (Objekte bleiben übrig – who cares ☺ )
- keine `for`-Schleife, nur `while`-Schleife
- keine Ausnahmebehandlung (*exception handling*)
- keine Zeiger

# UE 2: Lexikalische Analyse (*Scanner*)


- MJ-Angabe.zip:
  - Compilerklassen (Token.java, Errors.java, Gerüst von Scanner.java, ...)
- MJ-Tests.zip
  - JUnit-Testfälle
  - nächste Woche in der UE:
    - Testen mit JUnit
    - Versionsverwaltung mit Subversion
- Abgabe
  - siehe Abgabeanleitung auf Homepage!
  - elektronisch bis Mi, 26.10.2005, 20:15
    - alle zum Ausführen benötigten Dateien
  - auf Papier bis Do, 27.10.2005, 08:15
    - nur Scanner.java