Struktur des *MicroJava*-Compilers

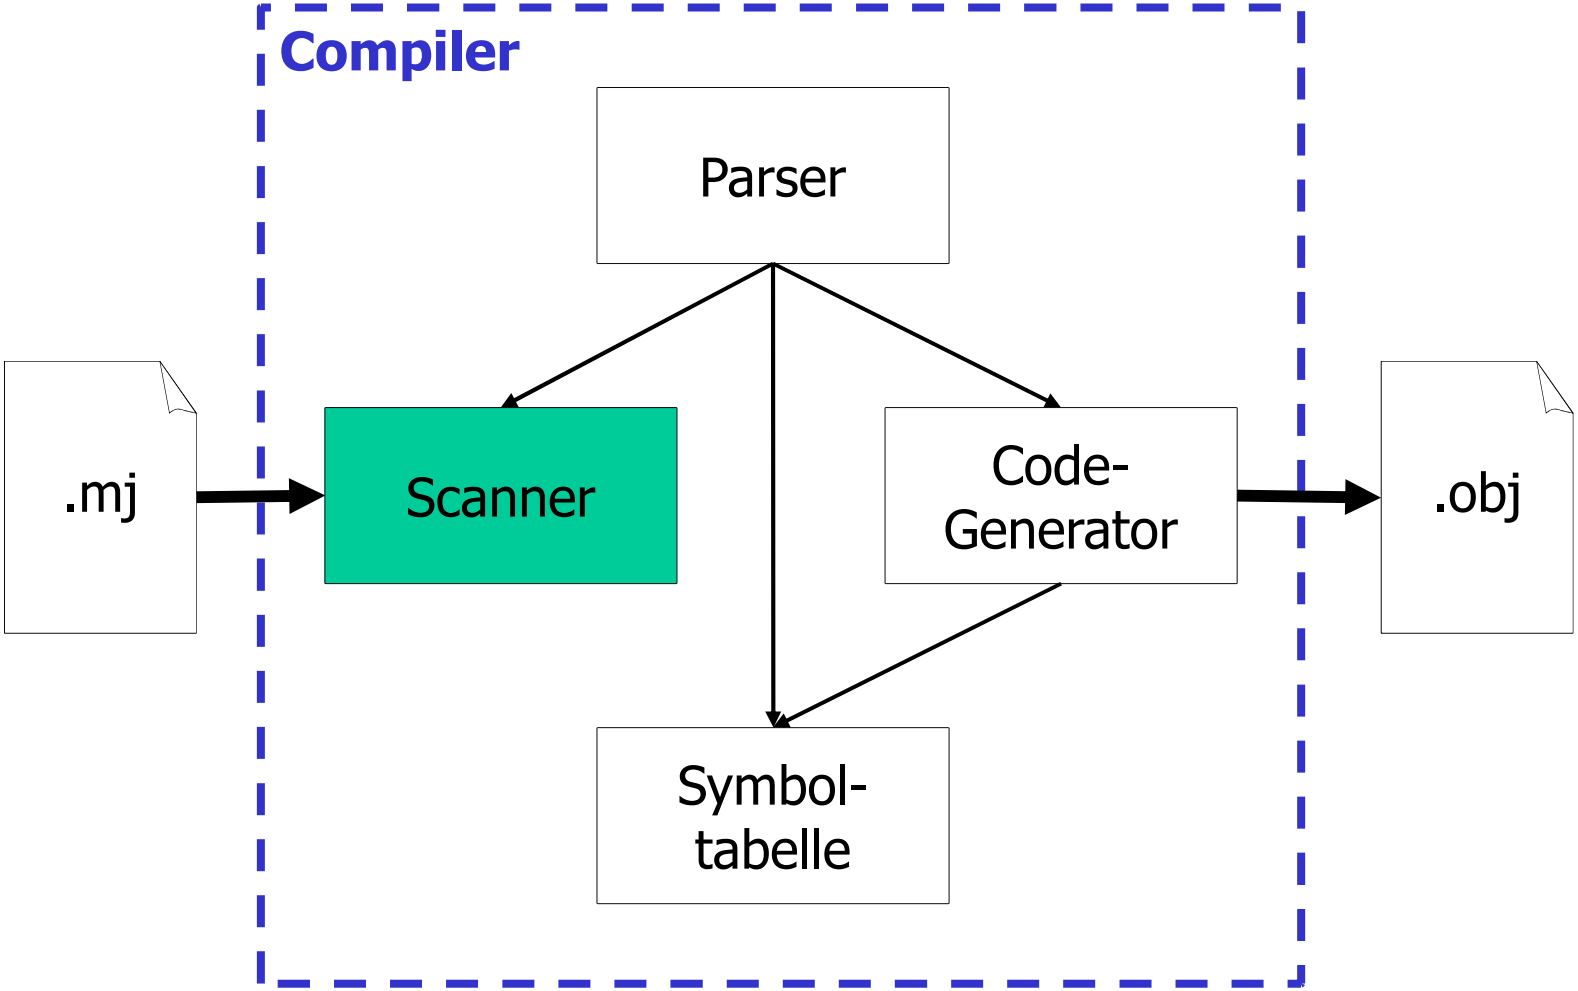

Grammatik ohne Scanner


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

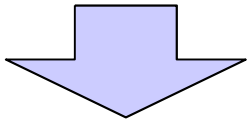

erlaube Kommentare an beliebiger Stelle

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

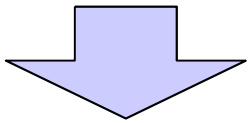

erlaube Whitespace an beliebiger Stelle

. . .

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

- Unterschiede zur Vorlesung
  - **Objekt-Felder:** Vereinfacht JUnit-Testfälle
  - **Enumerationen**: Typsicherheit bei Konstanten
- Diese Struktur muss beibehalten werden
  - Keine zusätzlichen Klassen nötig
  - Vollständig gegebene Klassen (= Klassen ohne TODO-Kommentar) gleich lassen

Fehlermeldungen

- Klasse **Errors** sammelt alle Fehlermeldungen
  void **error**(int line, int col, Message msg, Object... msgParams);

- Fehlermeldungen sind in Errors.Message definiert
  - Der error-Methode wird die Meldung übergeben
  - Manche Fehlermeldungen benötigen Parameter
    - Zusätzliche Parameter der error-Methode
  - Meldungstexte sind in der Enumeration definiert

- Hilfsmethode im Scanner (später auch im Parser)
  void **error**(Token t, Message msg, Object... msgParams);
  - Übernimmt die Fehlerposition aus dem angegebenen Token

Klasse Scanner + Token


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

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

- 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
- Bilden von Terminalklassen (ident, number, ...)
  int, char, null, chr, ord, len sind keine Schlüsselwörter,
  nur vordeklarierte Namen (→ Erkennung als ident)
- Erkennen des Dateiendes
- Melden lexikalischer Fehler (Zahlenformat, ungültige Zeichen, ...)
- Einstellen der Token-Attribute (Symbolart, Position, Wert, ...)

Scanner.next() (1)


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

    Token t = new 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 = semicolon; nextCh(); break;
        case EOF: t.kind = eof; /* no nextCh()  */ break;
        //----- compound tokens
        case '=':
            nextCh();
            if (ch == '=') { t.kind = eql; nextCh(); }
            else { t.kind = assign; }
            break;
        case '/':
            nextCh();
            if (ch == '*') { skipComment(t); t = next(); /* recursion */ }
            else { . . . }  break;
        default:
            error(t, INVALID_CHAR, ch); nextCh();
            break;
    }
    return t;
}
```

Hilfsmethoden

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

Zahlen-Konstanten

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

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

Zeichen-Konstanten

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

- Fehlerhafte Zeichen-Konstanten
  - Kein Zeichen: `''` error(t, EMPTY_CHARCONST);
  - Fehlendes Ende: `'A` error(t, MISSING_QUOTE);
  - Escape-Sequenzen: `'\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 oder Importanweisungen
- kein GC oder `delete` (Objekte bleiben übrig – who cares ☺)
- nur `for`-Schleife
- keine Ausnahmebehandlung (*exception handling*)
- keine Zeiger

UE 2: Lexikalische Analyse (*Scanner*)

- Angabe
  - https://k<MatrNr>:<Passwort>@www.ssw.uni-linz.ac.at/hg/2009W/UB/k<MatrNr>
  - Klassengerüst
  - JUnit-Testfälle
- Abgabe
  - elektronisch bis Mi, 28.10.2009, 18:00
    - Taggen mit: Abgabe UE1
  - auf Papier
    - Scanner.java