



**ISA**

Institut für  
SoftwareArchitektur



TECHNISCHE HOCHSCHULE MITTELHESSEN



# Compilerbau cs1019

Th. Letschert

TH Mittelhessen Gießen

*University of Applied Sciences*

## Syntaxanalyse mit Parserkombinatoren

- Die Idee der Parser-Kombinatoren
- Parserkombinatoren in Scala

# Parserkombinatoren – Die Idee

## Die Idee der Parser-Kombinatoren

### Parser-Kombinatoren

- Parser-Kombinatoren kombinieren Parser zu neuen Parseern.
- Ein Parser-Kombinator nimmt Parser und macht daraus einen neuen Parser (Der Kombinator kombiniert Parser zu einem neuen Parser)

### Idee der Parserkombinatoren

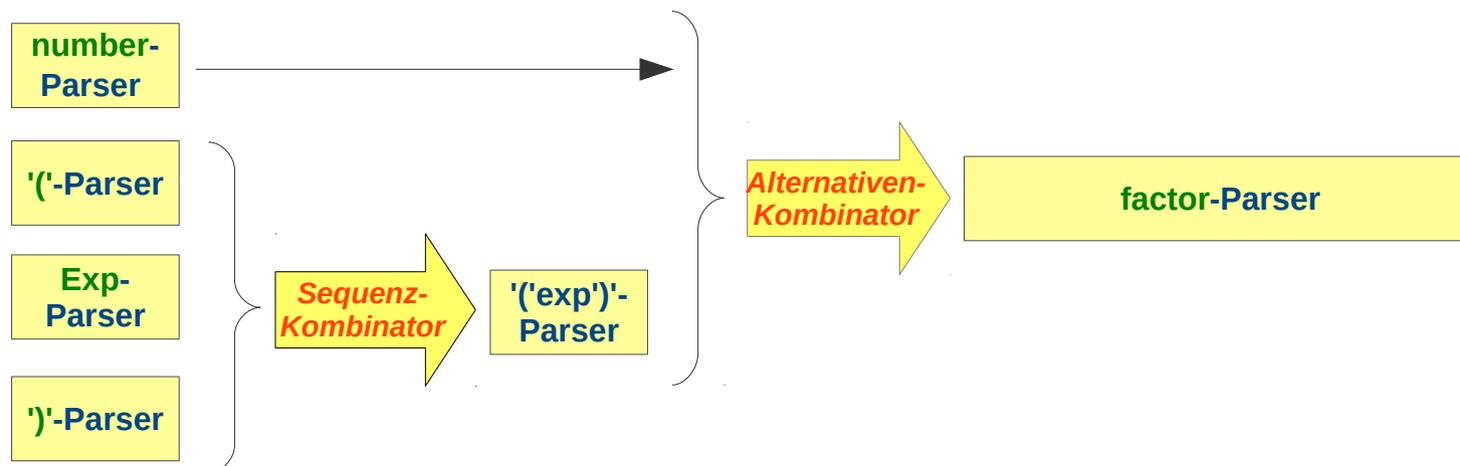
Parser werden aus anderen Parseern mit Hilfe von „Kombinatoren“ erzeugt,  
Ein Parser für ein komplexes Konstrukt wird mit

- einem (Parser-) Kombinator
- aus Parseern für einfachere Konstrukte

erzeugt.

### Beispiel

*factor ::= number | '(' exp ')'*



## Bestandteile einer kontextfreien Grammatik

### Produktionen

Eine Grammatik enthält Produktionen der Form:

$$A \rightarrow B_1 B_2 \dots B_n$$

$A$  ist dabei ein Nonterminal die  $B_i$  sind Terminale oder Nonterminale

### Alternativen

Produktionen mit der gleichen linken Seite werden zu Alternativen zusammengefasst:

$$A \rightarrow P_1 | P_2 | \dots | P_n$$

$A$  ist dabei ein Nonterminal und die  $P_i$  sind rechte Seiten von Produktionen

## Konstruktion eines Parsers

### Grammatik

Enthält Regeln der Form

$$A \rightarrow B_1 B_2 \dots B_n$$

$$A \rightarrow P_1 | P_2 | \dots | P_n$$

### Parser für eine Grammatik

Ein Parser für eine solche Grammatik kann man konstruieren

- aus jeweils einen Parser für jedes Terminal
- mit diesen kann man einen Parser für jede rechte Seite (Body) einer Produktion

$$B_1 B_2 \dots B_n$$

konstruieren

- und aus diesen einen Parser für die Alternativen jedes Nonterminals

$$A \rightarrow P_1 | P_2 | \dots | P_n$$

- Der Parser für das Startsymbol ist dann der gesuchte Parser

## Konstruktion eines Parsers aus einer Grammatik

### Parser für Terminale

Parser für Terminale können mit den üblichen Verfahren für die Erkennung regulärer Sprachen realisiert werden.

$$A \rightarrow [1-9][0-9]^*$$

### Parser für Produktionen

Parser für Produktionen müssen eine **Folge / Sequenz** von Terminalen und Nichtterminalen erkennen.

Hat man einen Parser für jeden Bestandteil einer Produktion, dann kann man aus ihnen Parser für die gesamte Produktion konstruieren.

$$A \rightarrow XY$$

### Parser für Nonterminale / Alternativen

Parser für Nichtterminale müssen eine von mehreren alternativen Produktionen erkennen.

Hat man für jede Produktion einen Parser für jede Alternative, dann kann man aus ihnen einen Parser das Nichtterminal konstruieren.

$$A \rightarrow X | Y$$

## Konstruktion eines Parsers mit Parserkombinatoren

### Parser für Terminale

Parser für Terminale können mit den üblichen Verfahren für die Erkennung regulärer Sprachen realisiert werden.

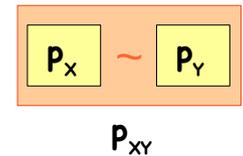
### Parserkombinator für Produktionen

Parser für Produktionen werden von einem **Kombinator**  $C_{\sim}$  für Produktionen erzeugt:

Ein **Kombinator**  $C_{\sim}$  für Produktionen

konstruiert aus einem Parser  $p_x$  für  $X$  und einem Parser  $p_y$  für  $Y$  einem Parser  $p_{xY}$  für  $XY$

$$C_{\sim}(p_x, p_y) = p_{xY}$$



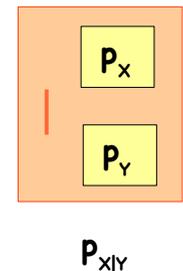
### Parserkombinator für Nonterminale / Alternativen

Parser für Nichtterminale werden von einem **Kombinator**  $C_{|}$  für Alternativen erzeugt:

Ein **Kombinator**  $C_{|}$  für Alternativen

konstruiert aus einem Parser  $p_x$  für  $X$  und einem Parser  $p_y$  für  $Y$  einen Parser  $p_{x|y}$  für  $Y|X$

$$C_{|}(p_x, p_y) = p_{x|y}$$



# Parser-Kombinatoren – Die Idee

## Funktionale Parser-Kombinatoren

### Beispiel:

Angenommen wir haben Parser-Funktionen die „1“ und „2“ parsen können:

```
def parse_1(text: List[Char]) : Option[(Number, List[Char])] =  
  if (text.head == '1') Some((Number(1), text.tail))  
  else None  
  
def parse_2(text: List[Char]) : Option[(Number, List[Char])] =  
  if (text.head == '2') Some((Number(2), text.tail))  
  else None
```

#### Die beiden Funktionen

- akzeptieren einen Text – hier der Einfachheit halber eine Liste von Chars
- testen, ob es sich um das richtige Zeichen handelt und
- geben im Erfolgsfall eine erkannte Zahl und den Rest des Textes zurück.

```
sealed abstract class ExpTree  
case class Number(v: Int) extends ExpTree
```

# Parser-Kombinatoren – Die Idee

## Funktionale Parser-Kombinatoren

### Beispiel:

Ein Parser, der „1 | 2“ parsen kann, ist auch leicht definiert:

```
def parse_1or2(text: List[Char]) : Option[(Number, List[Char])] =  
  parse_1(text) match {  
    case Some((num1, rest1)) => Some((num1, rest1))  
    case None => parse_2(text)  
  }
```

Die Funktionen versucht „1“ zu parsen und wenn das fehlschlägt, dann versucht sie es mit „2“

Diese Konstruktion kann zu einem Alternativen-Kombinator verallgemeinert werden:

```
def parseAlt(  
  parser_A: List[Char] => Option[(Number, List[Char])],  
  parser_B: List[Char] => Option[(Number, List[Char])]): List[Char] => Option[(Number, List[Char])] = {  
  (text: List[Char]) =>  
    parse_A(text) match {  
      case Some((num1, rest1)) => Some((num1, rest1))  
      case None => parse_B(text)  
    }  
}
```

Die Funktionen nimmt zwei Parser die **A** bzw. **B** parsen können und macht daraus einen Parser der **A|B** parsen kann.

# Parser-Kombinatoren – Die Idee

## Objektorientierte Parser-Kombinatoren

Die Konstruktion kann auch objektorientiert gestaltet werden:

Wir definieren ein Trait (Interface) für Parser und zwei primitive Parser:

```
trait Parser {  
  def parse(text: List[Char]) : Option[(Number, List[Char])]  
}
```

*Ein Parser-Interface*

```
object Parse_1 extends Parser {  
  def parse(text: List[Char]) : Option[(Number, List[Char])] =  
    if (text.head == '1') Some((Number(1), text.tail))  
    else None  
}
```

*Ein Parser für „1“*

```
object Parse_2 extends Parser {  
  def parse(text: List[Char]) : Option[(Number, List[Char])] =  
    if (text.head == '2') Some((Number(2), text.tail))  
    else None  
}
```

*Ein Parser für „2“*

## Objektorientierte Parser-Kombinatoren

Die Konstruktion eines Parsers für Alternativen ist jetzt eine Methode des Traits Parser:

```
trait Parser {  
  
  def parse(text: List[Char]) : Option[(Number, List[Char])]  
  
  def alt(other: Parser): Parser = {  
    val outer = this  
    new Parser{  
      def parse(text: List[Char]): Option[(Number, List[Char])] =  
        outer.parse(text) match {  
          case Some(result) => Some(result)  
          case None          => other.parse(text)  
        }  
    }  
  }  
}
```

*Ein Parserkombinator für Alternativen*

```
println(Parse_1.alt(Parse_2).parse("2".toCharArray().toList))
```

Some((Number(2),List()))

## Objektorientierte Parser-Kombinatoren

Mit einem `|` als Methodename wird das Ganze noch etwas hübscher:

```
trait Parser {  
  
  def parse(text: List[Char]) : Option[(Number, List[Char])]  
  
  def |(other: Parser): Parser = {  
    val outer = this  
    new Parser{  
      def parse(text: List[Char]): Option[(Number, List[Char])] =  
        outer.parse(text) match {  
          case Some(result) => Some(result)  
          case None          => other.parse(text)  
        }  
    }  
  }  
}
```

*Ein Parserkombinator für |*

```
println((Parse_1 | Parse_2).parse("2".toArray().toList))
```

Some((Number(2),List()))

## Grammatik = Parser-Definition

Parser-Kombinatoren erlauben es „größere“ Parser aus „kleineren“ zusammen zu bauen

Mit moderner (funktionaler) Software-Technik können

**Parser-Definitionen** auf Basis von Parser-Kombinatoren

- so gestaltet werden, dass sie wie **Grammatik-Definitionen** aussehen, bzw.

Geeignete **Grammatik-Definitionen**

- als **Parser-Definitionen** interpretiert werden

# Parser-Kombinatoren – Die Idee

---

## Parser

die mit **Parser-Kombinatoren konstruiert** wurden, sind

- **Top-Down** Parser,
- die nur Grammatiken **ohne Links-Rekursion** verarbeiten können, und
- mit **Backtracking** arbeiten
  - Alternativen werden „der Reihe nach“ abgearbeitet und eventuell abgebrochen
  - Solange bis eine erfolgreich ist

## Parser-Kombinatoren nutzen

- Bequem und flexibel verwendbare Parser-Kombinatoren – speziell in einer typisierten Sprache – erfordern einen gewissen Softwaretechnischen Aufwand, auf den wir hier nicht eingehen wollen.
- Die Grundidee ist aber einfach und wir nutzen die Parser-Kombinatoren von Scala ohne auf technische Details einzugehen.

## Parser-Kombinatoren

Einfach und elegant, aber mit allen Nachteilen des Top-Down-Backtracking-Parsens:

- unter Umständen exponentielle Laufzeit
- Linksrekursion nicht erlaubt
- Mehrdeutigkeit problematisch

Die erste Alternative wird verfolgt und kann – wenn erfolgreich geparkt werden kann – dazu führen, dass alternative Regeln mit gleichem Anfang nicht in Betracht gezogen werden.

Z.B. *Dangling Else* – Problem

$\text{exp} ::= \text{exp} + \text{exp} \mid \text{const}$

*Linksrekursion*

$\text{stmt} ::= \text{if } \text{expr} \text{ then } \text{stmt}$   
 $\mid \text{if } \text{expr} \text{ then } \text{stmt} \text{ else } \text{stmt}$

*Mehrdeutige Grammatik:  
ein String hat mehr als eine passende  
Produktion*

## Parser-Kombinatoren

- Idee von Philip Walder als Anwendungsbeispiel des funktionalen Programmierens  
Mitte der 1980er
- Konzept: *Top-Down-Backtracking* Parser  
Implementierung einer Top-Down-Backtracking Parsing-Technik: Erkennungsfunktionen für jede Regel, mit Backtracking bei Misserfolg

## PEG: Parsing Expression Grammar

Eine **Grammatik** definiert eine unendliche Menge  
durch einen (nicht-deterministischen) **Erzeugungsprozess**

Ein **Parser** ist ein **Erkennungs-Algorithmus**

**Grammatik => Parser**

Definiere einen Erkennungsalgorithmus, der zum Erzeugungsprozess kompatibel ist

**PEG:**

- Definiere Grammatik und **interpretiere** sie als **Erkennungsalgorithmus**
- „Trick“ der Parsing mit Parser-Kombinatoren rechtfertigt:
  - Statt: Grammatik => Sprache <=> Parser
  - Jetzt: Grammatik = Sprache = Parser
- Von Bryan Ford definiert / popularisiert (siehe <http://www.brynosaurus.com/pub/lang/peg.pdf>)
- Basis / Rechtfertigung von Parser-Kombinatoren
  - Der Nichtdeterminismus wird als Reihenfolge der Versuche umgedeutet
  - Thema einer Veranstaltung zu Parsing / formalen Sprachen

## Packrat-Parser

### Backtrack-Parser

- Parser, die Alternativen untersuchen  
Backtracking: Suche ist Tiefensuche  
Problem: Suche kann sich in einem endlichen Unterraum verlieren, obwohl sie in einem anderen Unterraum erfolgreich wäre
- Suchstrategie ist relevant  
in der Regel von links nach rechts  
Grammatik: **Reihenfolge der Alternativen beachten!**

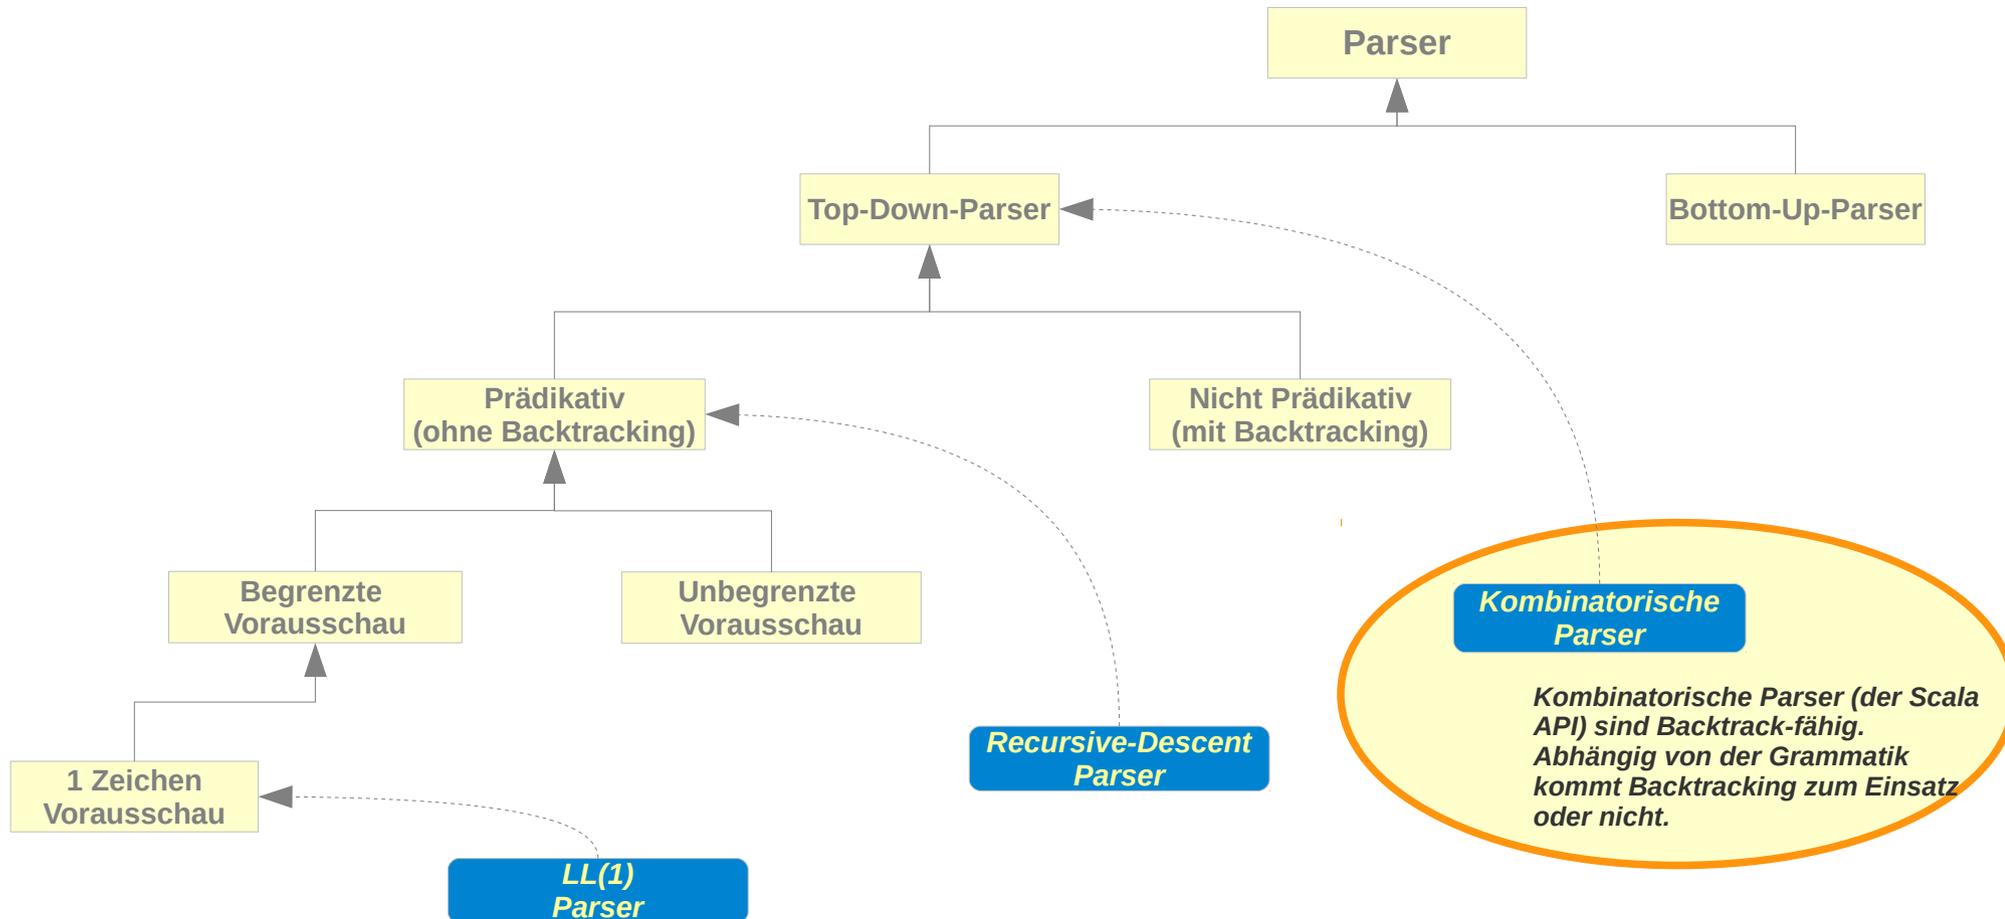
### Prädikative Parser

- Backtracking-freie Top-Down Parser  
Beispiel: Recursive-Descent-Parser

### Packrat-Parser

- Parser der Ergebnisse „hamstert“ (Packrat: ein hamsterartiges kleines Pelztier)
- Merkt sich, welche (Teil-) Eingabe bereits geparkt wurde
- Kommt darum mit links-rekursiven Grammatiken klar
- Thema einer Veranstaltung zu Parsing / formalen Sprachen

## Parser – Überblick mit kombinatorischen Parsern



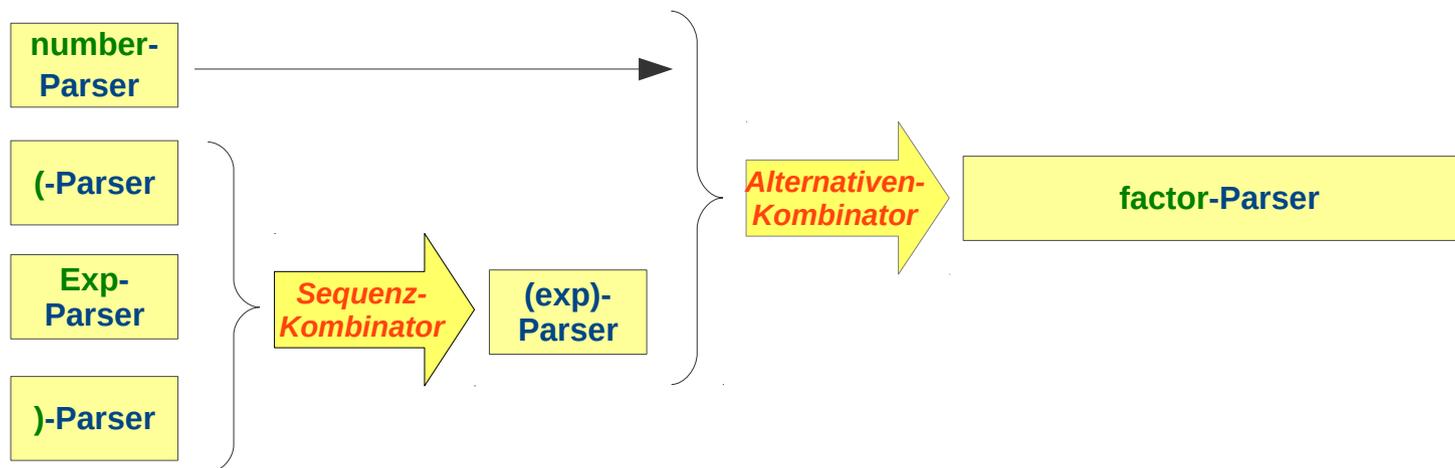
## Parser-Kombinatoren in Scala

### Beispiel

Grammatik-Fragment

*factor ::= number | '(' exp ')'*

Parser-Konstruktion



# Parser-Kombinatoren in Scala

## Beispiel

Beispiel aus Odersky, Spoon, Venners: „Programming in Scala“, 2nd edition artima

```
exp ::= term { ('+' | '-') term }  
term ::= factor { ('*' | '/') factor }  
factor ::= number | '(' exp ')'
```

Grammatik in EBNF-Form

Parser für diese Grammatik

Die Produktionen der Grammatik werden als Parser formuliert.  
Die Parser erzeugen aus Strings die Ableitungsbäume entsprechend der (konkreten) Syntax.

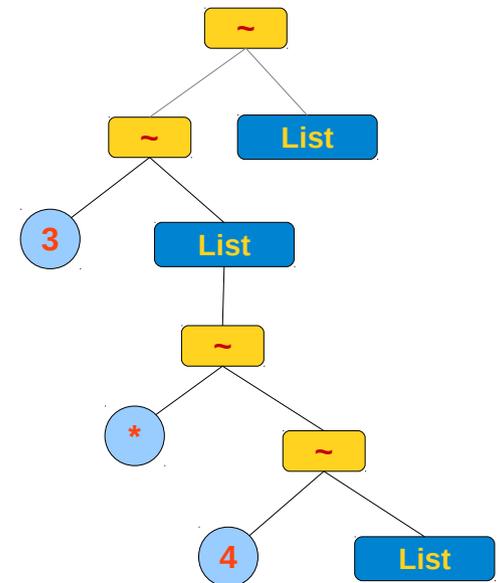
```
package parsing.ex_1  
  
import scala.util.parsing.combinator.JavaTokenParsers  
  
object FormulaParser extends JavaTokenParsers {  
  
  def exp: Parser[Any] = term ~ rep(("+" | "-") ~ term )  
  def term: Parser[Any] = factor ~ rep(("*" | "/" ) ~ factor )  
  def factor: Parser[Any] = floatingPointNumber | "(" ~ exp ~ ")"  
  
}  
  
object SimpleFormula_App extends App {  
  println(FormulaParser.parseAll(FormulaParser.exp, "3*4"))  
}
```

Ergebnis des Parsens von „3\*4“:  
Ableitungsbaum . toString

```
[1.4] parsed: parsed:  
((3~List((*~(4~List()))))~List())
```

```
(  
  ( 3 ~  
    List(  
      ( * ~  
        (4 ~ List())  
      )  
    )  
  ) ~  
  List()  
)
```

Ableitungsbaum in Textform



Ableitungsbaum als Baum

## Kombinatorisches Parsing

$exp ::= term \{ ('+' | '-') term \}$

$term ::= factor \{ ('*' | '/') factor \}$

$factor ::= number | '(' exp ')'$

EBNF-Form: implizite Operatoren

„ “ (nichts)	Sequenz (Aufeinanderfolge)
„{ ... }“	Wiederholung
„ “	Alternative

$exp ::= term \{ ('+' | '-') term \}$

$exp$  ist eine Sequenz  
aus einem  $term$   
gefolgt von einer Wiederholung von  
einer Sequenz von einer  
Alternative von '+' und '-'  
gefolgt von einem  $term$

Für einen Parser für  $exp$   
benötigen wir **Parser** für  
 $Terme$ ,  
„+“-Zeichen und  
„-“-Zeichen  
und **Parserkombinatoren** für  
Sequenzen,  
Wiederholungen,  
Alternativen

## Parser-Kombinatoren in Scala

- Parser-Kombinatoren sind eine Grundübung in funktionaler Programmierung
- Jede Sprache die „anständig funktional“ sein will, wird mit Parser-Kombinatoren „getestet“
- Scala hat Parser-Kombinatoren als Teil der API von Anfang an „offiziell“ unterstützt
- Um die Scala-API überschaubar zu halten wurde sie ab Scala 2.11 modularisiert: es ist nicht mehr alles „automatisch“ enthalten:
  - Kern (scala.lib) + eventuell weitere Module
- Parser-Kombinatoren nicht Bestandteil von scala.lib
- Die entsprechende jar-Datei muss explizit geladen und referenziert werden (Siehe Scala-Doku)

beispielsweise so:

- Lade / Installiere Scala
- In Eclipse:

Einstellungen: new User-Library *Parsing*;

add external Jars : aus der Scala-Installation: *lib/scala-parser-combinators\_... .jar*

im Projekt: add User-Library *Parsing*

oder in build.sbt so etwas wie:

- `libraryDependencies += "org.scala-lang.modules" %% "scala-parser-combinators" % "1.0.6"`

# Parser-Kombinatoren in Scala

## Beispiel

Ein **kombinatorischer** Parser wird mit Hilfe von

- anderen Parsern und
- Parserkombinatoren

definiert.

Die Parserkombinatoren kombinieren Parser zu neuen Parsern

**factor** ::= *number* | '(' *exp* ')'



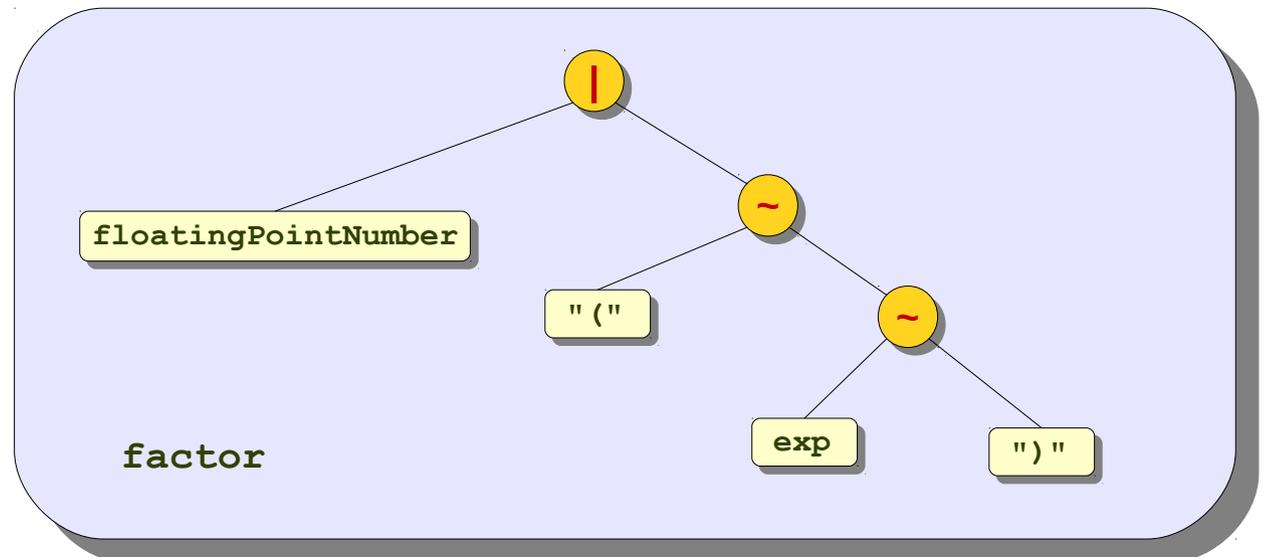
```
def factor: Parser[Any] = floatingPointNumber | "(" ~ exp ~ ")"
```

### Genutzte Parser

- `floatingPointNumber`
- `exp`
- `" ("`
- `") "`

### Parserkombinatoren

- `|` Alternative
- `~` Verkettung



## Beispiel

`exp ::= term { ('+' | '-') term }`

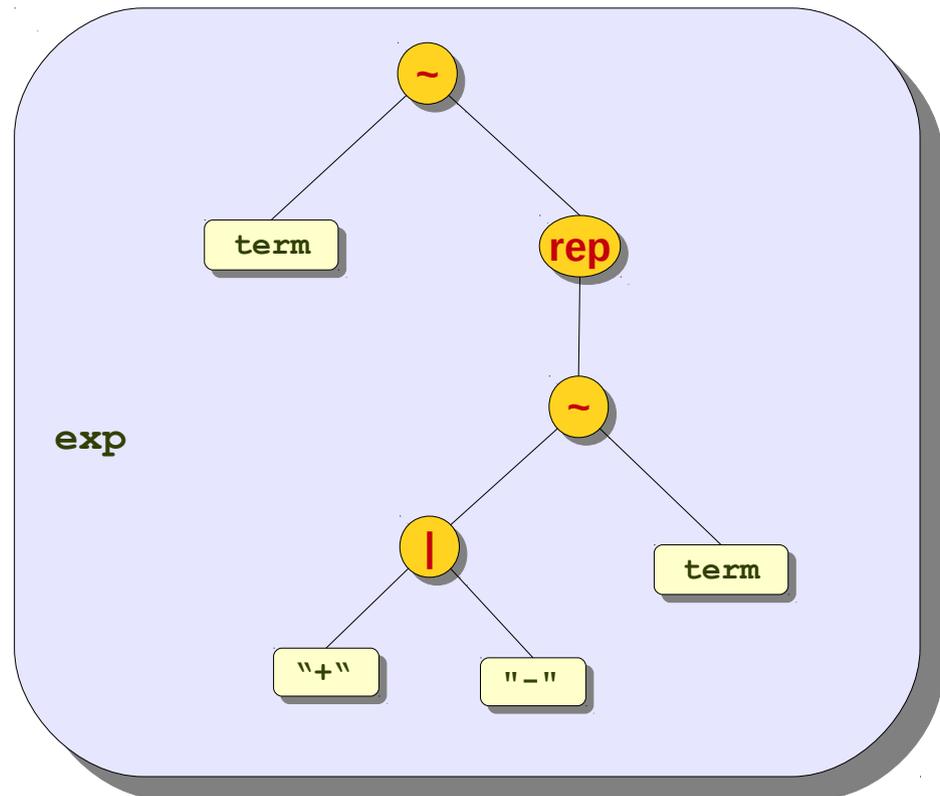
➔ `def exp: Parser[Any] = term ~ rep(("+" | "-") ~ term )`

### Genutzte Parser

- `term`
- `factor`
- `"(" ein Scanner für (`
- `")" ein Scanner für )`

### Parserkombinatoren

- `|` Alternative
- `~` Verkettung
- `rep` Wiederholung



# Parser-Kombinatoren in Scala

## Parser und ihre Nutzung

Für jede kontextfreie Grammatik in EBNF-Form kann so ein Parser definiert werden.

### Nutzung

**parseAll** : Methode einer Parser-Klasse (*parst* die gesamte Eingabe)

Argumente: Parser, Eingabe

Ergebnis: konkreter Syntaxbaum

```
sealed abstract class ParseResult[+T] extends AnyRef
  A base class for parser results.

def parseAll[T](p: Parser[T], in: Reader): ParseResult[T]
  Parse all of reader in with parser p.
```



Klasse definiert in  
*scala.util.parsing.combinator.Parsers*



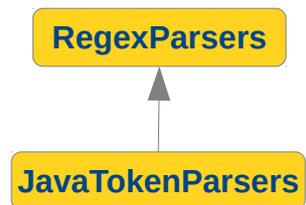
Methode definiert in  
*scala.util.parsing.combinator.RegexParsers*

### RegexParsers

Reguläre Ausdrücke können als Parser ihrer Sprache verwendet werden

### JavaTokenParsers

Vordefinierte reguläre Ausdrücke für „Java-Tokens“ können verwendet werden



# Parser in der Scala API

## JavaTokenParsers

Definiert reguläre Ausdrücke die Java-Tokens beschreiben

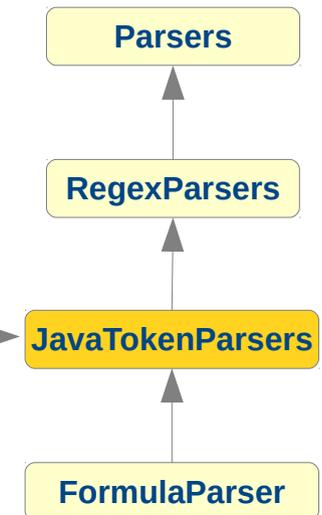
```
object FormulaParser extends JavaTokenParsers {  
  def exp: Parser[Any] = term ~ rep(("+" | "-") ~ term )  
  def term: Parser[Any] = factor ~ rep(("*" | "/" ) ~ term )  
  def factor: Parser[Any] = floatingPointNumber | "(" ~ exp ~ ")"  
}
```

```
def floatingPointNumber: Parser[String] =  
  ""-?(\d+(\.\d*)?|\d*\.\d+) ([eE] [+]? \d+)? [fFdD]? "" .r
```

Definiert in `scala.util.parsing.combinator.JavaTokenParsers`

`JavaTokenParsers` bietet Parser für folgende Tokenklassen:

- `ident`
- `wholeNumber`
- `decimalNumber`
- `stringLiteral`
- `floatingPointNumber`



## JavaTokenParsers

```
import scala.util.parsing.combinator.JavaTokenParsers

trait ExpParser extends JavaTokenParsers {
  def exp: Parser[Any] = term~"+"~term | term
  def term: Parser[Any] = factor~"*"~factor | factor
  def factor: Parser[Any] = decimalNumber | "("~exp~")"
}

object Test extends App with ExpParser {
  println(parseAll(exp, "(3 * 4) + 1 * 2"))
}
```

### Parser für die Grammatik

```
exp ::= term '+' term | term
term ::= factor * factor | factor
factor ::= decimalNumber | '(' exp ')'
```

`term~"+"~term` : Zwei Parser-Funktionen `term`, `"+"` werden mit dem Kombinator `~` zu einem neuen Parser verknüpft

### Parser

`exp` : Parser-Funktion für `exp`  
`term` : Parser-Funktion für `term`  
`factor`: Parser-Funktion für `factor`  
`decimalNumber`: Scanner-Funktion für Zahlen  
`"+"` : Scanner-Funktion für `„+“`  
`"*"` : Scanner-Funktion für `„*“`

### Parser-Kombinatoren

`~` : Verkettung  
`|` : Alternative

# Parser in der Scala API

## Beispiele

```
import scala.util.parsing.combinator.JavaTokenParsers

trait ExpParser extends JavaTokenParsers {
  def exp: Parser[Any] = term ~ rep("+" ~ term | "-"~term)
  def term: Parser[Any] = factor~rep("*"~factor | "/"~factor)
  def factor: Parser[Any] = decimalNumber | "("~exp~")"
}

object Test extends App with ExpParser_3 {
  println(parseAll(exp, "3 * 4 * (5 + 6)"))
}
```

```
import scala.util.parsing.combinator.JavaTokenParsers

trait ExpParser extends JavaTokenParsers {
  def exp : Parser[Any] = number ~ rep(op ~ number)
  def number = "[1-9]\\d".r
  def op      = "[\\|°]".r
}

object Test extends App with ExpParser_4 {
  println(parseAll(exp, "12 ° 13 | 20"))
}
```

## Parser-Kombinatoren

~ : Verkettung

| : Alternative

rep : Wiederholung 0 oder mehrmals

## Parser für die Grammatik

```
exp ::= term { '+' term | '-' term }*
term ::= factor { '*' factor | '/' factor }*
factor ::= decimalNumber | '(' exp ')'
```

*Grammatik ist nicht links-rekursiv*

## Parser für die Grammatik

```
exp ::= number { op exp }*
op   ::= '°' | '|'
number ::= zweistellig ohne führende 0
```

*Grammatik nutzt Tokens die mit regulären Ausdrücken definiert werden*

# Parser in der Scala API

## Beispiel

```
import scala.util.parsing.combinator.JavaTokenParsers

trait ExpParser_5 extends JavaTokenParsers {
  def exp: Parser[Any] = term ~ rep("+ ~ term | "-" ~ term)
  def term  = factor ~ rep("* ~ factor | "/" ~ factor)
  def factor = wholeNumber | "(" ~ exp ~ ")" | call
  def call   = ident ~ "(" ~ repsep(exp, ",") ~ ")"
}

object Test extends App with ExpParser_5 {
  println(parseAll(exp, "f(5, g(6, 7)) + 8 * h(9)"))
}
```

### *Parser-Kombinatoren*

**~** : Verkettung

**|** : Alternative

**rep** : Wiederholung 0 oder mehrmals

**repsep** : Wiederholung mit Trenner

### *Parser für die Grammatik*

```
exp ::= term { '+' term | '-' term }*
term ::= factor { '*' factor | '/' factor }*
factor ::= wholeNumber | '(' exp ')' | call
call ::= idnet '(' param ')'
param ::= exp | exp ',' param
```

# Parser in der Scala API

## JavaTokenParsers

Parserkombinatoren die im Trait `JavaTokenParsers` definiert oder ererbt werden

<code>decimalNumber</code>	eine Dezimalzahl
<code>floatingPointNumber</code>	eine Fließkommazahl (Dezimalzahl mit opt. Vorzeichen und E-Notation)
<code>wholeNumber</code>	ganze Zahl, eventuell mit Vorzeichen
<code>ident</code>	Bezeichner
<code>literal(String)</code>	Literal
<code>stringLiteral</code>	ein String in Hochkommas
<code>opt(P)</code>	optionales Vorkommen von $P$
<code>rep(P)</code>	wiederholtes Vorkommen von $P$ (0 oder mehrmals)
<code>rep1(P)</code>	wiederholtes Vorkommen von $P$ (mindestens einmal)
<code>repN(n, P)</code>	wiederholtes Vorkommen von $P$ (genau $n$ mal)
<code>repsep(P, Q)</code>	Wiederholungen von $P$ die durch $Q$ getrennt sind (0 oder mehrmals)
<code>rep1sep(P, Q)</code>	Wiederholungen von $P$ die durch $Q$ getrennt sind (mindestens einmal)
<code>P ~ Q</code>	Sequenz von $P$ und $Q$
<code>P   Q</code>	Alternative $P$ oder $Q$

# Parser-Kombinatoren: Eine DSL

## Kombinatorisches Parsing : Interne DSL von Scala

Parserkombinatoren sind ein Beispiel für eine **interne DSL**

**DSL** : Domain Specific Language

**Varianten** einer DSL

- **externe DSL**

DSL als eigenständige Sprache

Programme werden von eigenständigen Tools verarbeitet

- **interne DSL**

DSL als eingebettete Sprache: DSL-Konstrukte sind Teil der Wirts-Sprache

Programme werden von den Tools der Wirt-Sprache verarbeitet

```
def ~ [U] (q: => Parser[U]): Parser[~[T, U]]
```

Kombinator ~:

Methode eines Parsers mit Argument vom Typ Parser, liefert Ergebnis vom Typ Parser;

definiert in *scala.util.parsing.combinator.Parsers.Parser*

*Parserkombinatoren sind kein Sprachbestandteil, sondern „ganz normale“ Methoden.*

# Scala Parser-Kombinator-API

## Parser

Ein Parser – definiert im Trait `Parsers` – ist eine Funktion, die

- eine Eingabe (teilweise) konsumiert und
- ein Parsing-Ergebnis liefert
- das Parsing-Ergebnis beinhaltet einen Eingabe-Rest

```
trait Parsers {  
  type Elem  
  
  type Input = Reader[Elem]  
  
  sealed abstract class ParseResult[+T] { ... }  
  
  case class Success[+T](result: T, override val next: Input) extends ParseResult[T] { ... }  
  sealed abstract class NoSuccess(val msg: String, override val next: Input) extends ParseResult[Nothing] { ... }  
  
  abstract class Parser[+T] extends (Input => ParseResult[T]) { ... }  
}
```

**Siehe auch:**

- API-Doku: [https://static.javadoc.io/org.scala-lang.modules/scala-parser-combinators\\_2.12/1.0.6/index.html](https://static.javadoc.io/org.scala-lang.modules/scala-parser-combinators_2.12/1.0.6/index.html)
- A. Moors, F. Piessens, M. Odersky: *Parser Combinators in Scala*  
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.142.5002&rep=rep1&type=pdf>

# Scala Parser-Kombinator-API

## Parser

### Typ-Parameter T

- Typ des Ergebnisses des Parsings
- in der Regel ein AST (Parser im üblichen Sinn) oder eine Sequenz von Tokens (Scanner)

```
trait Parsers {  
  type Elem  
  type Input = Reader[Elem]  
  
  sealed abstract class ParseResult[+T] { ... }  
  
  /** The success case of `ParseResult`: contains the result and the remaining input.  
   *  
   * @param result The parser's output  
   * @param next   The parser's remaining input  
   */  
  case class Success[+T](result: T, override val next: Input) extends ParseResult[T] { ...  
}  
  sealed abstract class NoSuccess(val msg: String, override val next: Input) extends ParseResult[Nothing] { ... }  
  
  abstract class Parser[+T] extends (Input => ParseResult[T]) { ... }  
}
```

## Parser: Token-Parser und Character-Parser

### Typ Elem

- Typ der Elemente, aus denen die Eingabe besteht
- Scanner und Parser werden nicht an Hand der Eingabe unterschieden
- Scanner und Parser werden nicht an Hand der Grammatik unterschieden: Parser können reguläre Sprachen erkennen

```
trait Parsers {
```

```
  /** the type of input elements the provided parsers consume (When consuming  
   * individual characters, a parser is typically called a 'scanner', which  
   * produces 'tokens' that are consumed by what is normally called a 'parser'.  
   * Nonetheless, the same principles apply, regardless of the input type.) */
```

```
  type Elem
```

```
  type Input = Reader[Elem]
```

```
  sealed abstract class ParseResult[+T] { ... }
```

```
  case class Success[+T](result: T, override val next: Input) extends ParseResult[T] { ... }
```

```
  sealed abstract class NoSuccess(val msg: String, override val next: Input) extends ParseResult[Nothing] { ... }
```

```
  abstract class Parser[+T] extends (Input => ParseResult[T]) { ... }
```

```
}
```

## Character-Parser

### RegExParsers

- Parser für einen Input, der aus Chars besteht
- Strings und Reguläre Ausdrücke können als Parser genutzt werden
- Unterklasse `JavaTokenParsers` definiert reguläre Ausdrücke für die typischen Java-Tokens

```
trait RegexParsers extends Parsers {  
  type Elem = Char  
  ...  
}
```

```
trait JavaTokenParsers extends RegexParsers {  
  ...  
}
```

## Token-Parser

### TokenParsers

- Parser für einen Input, der aus Tokens besteht
- Unterklasse StdTokenParsers definiert Parser für Standard-Tokens (numerische Literale, Bezeichner, Strings)

```
trait TokenParsers extends Parsers {  
  type Tokens <: token.Tokens  
  ...  
}
```

```
trait StdTokenParsers extends TokenParsers {  
  type Tokens <: StdTokens  
  ...  
}
```

# Konkrete => abstrakte Syntax

## Definition des AST

```
// Sorte Exp
sealed abstract class Exp

// Operatoren
case class Plus(l: Exp, r: Exp) extends Exp
case class Times(l: Exp, r: Exp) extends Exp
case class Const(n: Int) extends Exp
```

## Case-Klassen

- eine Variante der Klassendefinition, die eingesetzt wird für Klassen
- deren Exemplare (typischerweise) unveränderlich sind
  - deren Exemplare mit Pattern-Matching verarbeitet werden sollen

Case-Classes bieten

- generierte Methoden equals und hashCode
- generierte Getter und Setter für die Konstruktor-Parameter
- eine generierte toString-Methode

Case-Classes ~ algebraische Datentypen

- eignen sich zur Definition von algebraischen Datentypen  
(also von *geordneten Bäume mit typisierten Knotenkonstruktoren*)

## Sealed Classes

dürfen nur in der Quelldatei abgeleitet werden, in der sie definiert sind.

Verbessert Pattern-Matching:  
alle Möglichkeiten sind fix und dem Compiler bekannt

# Konkrete => abstrakte Syntax

## Konstruktion des AST

Beispiel: Ausdrücke parsen und einen AST vom Typ **Exp** erzeugen

```
import scala.util.parsing.combinator.JavaTokenParsers

// Sorte Exp
sealed abstract class Exp

// Operatoren
case class Const(n: Int) extends Exp
case class Plus(l: Exp, r: Exp) extends Exp
case class Times(l: Exp, r: Exp) extends Exp

object ExpParser extends JavaTokenParsers {

  def exp: Parser[Exp] = decimalNumber ^^ { d => Const(d.toInt) } |
    plus |
    times

  def plus: Parser[Exp] = "(" ~ exp ~ "+" ~ exp ~ ")" ^^ { case "(" ~ e1 ~ "+" ~ e2 ~ ")" => Plus(e1, e2) }

  def times: Parser[Exp] = "(" ~ exp ~ "*" ~ exp ~ ")" ^^ { case "(" ~ e1 ~ "*" ~ e2 ~ ")" => Times(e1, e2) }
}

object AstBuilding_App extends App {
  println(ExpParser.parseAll(ExpParser.exp, "((2 + 3) * (4 + 5))"))
}
```



```
[1.20] parsed:
Times(Plus(Const(2), Const(3)), Plus(Const(4), Const(5)))
```

# Konkrete => abstrakte Syntax

## ^^ Kombinator: Transformation von Parsern

```
/** A parser combinator for function application.
 *
 * `p ^^ f` succeeds if `p` succeeds; it returns `f` applied to the result of `p`.
 *
 * @param f a function that will be applied to this parser's result.
 * @return a parser that has the same behaviour as the current parser, but whose result is
 *         transformed by `f`.
 */
def ^^ [U](f: T => U): Parser[U] = ...
```

### Der ^^ Kombinator

wird in `scala.util.parsing.combinator.Parsers.Parser` als (Operator-) Methode definiert und ist ein Transformator für Parsing-Ergebnisse.

Ein Parser der T-Objekte erzeugt wird durch die Methode ^^ mit einer Funktion, die T-Objekte in U-Objekte abbildet, transformiert zu einem Parser der U-Objekte erzeugt

`Parser[T].^^(T => U)` erzeugt einen `Parser[U]`

# Konkrete => abstrakte Syntax

## ^^ Kombinator

### Beispiel

```
decimalNumber ^^ { d => Const(d.toInt) }
```

Funktion:  $d \Rightarrow \text{Const}(d.\text{toInt})$

Wird genutzt in

```
def exp: Parser[Exp] = decimalNumber ^^ { d => Const(d.toInt) }
```

In `scala.util.parsing.combinator.JavaTokenParsers` ist definiert:

```
def decimalNumber: Parser[String]
```

Es ist ein Parser der **Strings** erzeugt,

die Funktion `{ d => Const(d.toInt) }` macht aus einem String ein **Exp**-Objekt,

als Argument der Methode `^^` wird aus einem Parser der Strings erzeugt, ein Parser der ein **Exp** erzeugt.

```
Parser[String] ^^ (String => Exp) = Parser[Exp]
```

# Konkrete => abstrakte Syntax

## ^^ Kombinator

### Beispiel

```
"(" ~ exp ~ "+" ~ exp ~ ")" ^^ { case "(" ~ e1 ~ "+" ~ e2 ~ ")"  
=> Plus(e1, e2) }
```

Funktionsdefinition via Pattern-Match:

Das Parsing-Ergebnis wird mit

```
"(" ~ e1 ~ "+" ~ e2 ~ ")"
```

verglichen und dabei werden die Variablen e1 und e2 an die „gematchten“ Werte gebunden.

```
def fun_0 (x : AorB): Unit = x match {  
  case A => println("an A")  
  case B => println("an B")  
}  
  
<==>  
val fun_1: AorB => Unit = {  
  case A => { println("an A") }  
  case B => { println("an B") }  
}
```

Etwas Scala-Magie: Kurz-Notation für Funktionen mit einem Argument, die aus einem Match auf diesem Argument bestehen.

# Konkrete => abstrakte Syntax

## Vereinfachungen mit $\sim>$ , $<\sim$

```
def plus: Parser[Exp] = "("~exp~"+"~exp~")" ^^ { case "(" ~ e1 ~ "+" ~ e2 ~ ")"  
                                         => Plus(e1, e2) }
```



```
def plus: Parser[Exp] = "(" ~> exp <~ "+" ~ exp <~ ")" ^^ { case e1 ~ e2  
                                         => Plus(e1, e2) }
```

$P \sim> Q$  : Das Gesamtergebnis ist das von Q (parse und dann vergiss P)

$P <\sim Q$  : Das Gesamtergebnis ist das von P (parse und dann vergiss Q)

# Konkrete => abstrakte Syntax

## Listen parsen

### Übernahme von Listen in den AST

```
// AST
sealed abstract class Exp
case class Const(n: Int) extends Exp
case class Call(fun: Symbol, args: List[Exp]) extends Exp
```

```
// konkrete Syntax
trait ExpParser extends JavaTokenParsers {
  def exp: Parser[Any] = wholeNumber | call
  def call: Parser[Any] = ident ~ "(" ~ repsep(exp, ",") ~ ")"
}
```



```
// konkrete Syntax mit AST-Konstruktion
trait ExpParser extends JavaTokenParsers {

  def exp: Parser[Exp] = wholeNumber ^^ { d => Const(d.toInt) } |
    call

  def call: Parser[Exp] = ident ~ ("(" ~> repsep(exp, ",") <~ ")") ^^
    { case id~args => Call(Symbol(id), args) }
}
```

# Konkrete => abstrakte Syntax

## Listen parsen

```
// AST
sealed abstract class Exp
case class Const(n: Int) extends Exp
case class Plus(l: Exp, r: Exp) extends Exp
case class Minus(l: Exp, r: Exp) extends Exp
case class Times(l: Exp, r: Exp) extends Exp
case class Div(l: Exp, r: Exp) extends Exp
```

```
// Konkrete Syntax
trait ExpParser_4 extends JavaTokenParsers {
  def exp: Parser[Any] = repsep(term, addOp)
  def addOp = "+" | "-"
  def term = repsep(factor, multOp)
  def multOp = "*" | "/"
  def factor = wholeNumber | "("~exp~")"
}
```

### Probleme bei der Baumkonstruktion:

Die Struktur der konkreten Syntax unterscheidet sich erheblich von der der abstrakten Syntax.

repsep wirft sein zweites Argument (i.d.R. ist dies das Trennzeichen) weg, das „Trennzeichen“ (+, -, \*, /) ist hier aber wesentlich für den Baumaufbau.

# Konkrete => abstrakte Syntax

## Listen parsen

### ^^^ und chain1

```
trait ExpParser extends JavaTokenParsers {  
  
  def exp: Parser[Exp]  
    = chain1(term, term, addOp)  
  
  def addOp : Parser[(Exp, Exp) => Exp]  
    = "+" ^^^ {(x:Exp, y: Exp) => Plus(x,y)} |  
      "-" ^^^ {(x:Exp, y: Exp) => Minus(x,y)}  
  
  def term = chain1(factor, factor, multOp)  
  
  def multOp : Parser[(Exp, Exp) => Exp]  
    = "*" ^^^ {(x:Exp, y: Exp) => Times(x,y)} |  
      "/" ^^^ {(x:Exp, y: Exp) => Div(x,y)}  
  
  def factor: Parser[Exp]  
    = wholeNumber ^^ { d => Const(d.toInt) } |  
      "("~>exp<~")" ^^ { e => e }  
}  
  
object Test extends App with ExpParser {  
  println(parseAll(exp, "2 * (3 + 4) - 5 / 6"))  
}
```

^^^ ist eine Variante von ^^:  
^^ Funktion; ^^^ Konstante  
^^^ c = { x => c }

### chain1

entspricht repsep1 und hat (hier) drei Argumente:

- P1 = Parser für der erste Listenelement
- P2 = Parser für weitere Listenelemente
- TP = Parser für den Trenner

Der Parser für den Trenner muss eine Funktion liefern, die (abhängig vom Trennsymbol) eine „Zusammenbau“-Funktion liefern.

`chain1(term, term, addOp)`

Parse eine Liste mit

- `term` als Parser für das erste Element
- `term` als Parser für weitere Elemente
- `addOp` als Funktion die Zwischenergebnisse verarbeitet

## Vollständiges Beispiel

```
object TestExpParser extends App {  
  println(  
    ExpParser.parse(  
      "2 + 3*(3+5)/2 - 2/3 ")  
    )  
}
```

### phrase

generiert einen Parser der den Input vollständig abarbeitet und auf Eingabeströme angewendet werden kann.

```
import scala.util.parsing.combinator.JavaTokenParsers  
import scala.util.parsing.input.CharSequenceReader  
  
// abstract Syntax Tree  
sealed abstract class Exp  
case class Const(n: Int) extends Exp  
case class Plus(l: Exp, r: Exp) extends Exp  
case class Minus(l: Exp, r: Exp) extends Exp  
case class Times(l: Exp, r: Exp) extends Exp  
case class Div(l: Exp, r: Exp) extends Exp  
  
// Parser  
object ExpParser extends JavaTokenParsers {  
  
  private def exp: Parser[Exp]  
    = chainl1(term, term, addOp)  
  
  private def addOp : Parser[(Exp, Exp) => Exp]  
    = "+" ^^ { (x:Exp, y: Exp) => Plus(x,y) } |  
      "-" ^^ { (x:Exp, y: Exp) => Minus(x,y) }  
  
  private def term = chainl1(factor, factor, multOp)  
  
  private def multOp : Parser[(Exp, Exp) => Exp]  
    = "*" ^^ { (x:Exp, y: Exp) => Times(x,y) } |  
      "/" ^^ { (x:Exp, y: Exp) => Div(x,y) }  
  
  private def factor: Parser[Exp]  
    = wholeNumber ^^ { d => Const(d.toInt) } |  
      "(" ~> exp <~ ")" ^^ { e => e }  
  
  def parse(s: String) : Exp =  
    phrase(exp)(new CharSequenceReader(s)) match {  
      case Success(e,_) => e  
      case NoSuccess(msg,_) => throw new IllegalArgumentException(  
        "Parser Error '" + s + "': " + msg)  
    }  
}
```

# Parser-Kombinatoren

## Dangling Else – Problem:

```
import scala.util.parsing.combinator.JavaTokenParsers

object IfThenElseParser extends JavaTokenParsers {

  def stmt: Parser[Any] =
    "if" ~ "(" ~ exp ~ ")" ~ "then" ~ stmt |
    "if" ~ "(" ~ exp ~ ")" ~ "then" ~ stmt ~ "else" ~ stmt |
    ident ~ ":@" ~ exp

  def exp: Parser[Any] = term ~ rep("<" | ">") ~ term )
  def term: Parser[Any] = factor ~ rep("*" | "/" | "*" | "/") ~ term )
  def factor: Parser[Any] = floatingPointNumber | ident | "(" ~ exp ~ ")"

}

object DanglingElseApp extends App {
  println(IfThenElseParser.parseAll(IfThenElseParser.stmt, "if (x>y) then a := 5 else a := 6"))
}
```

[1.22] **failure:** string matching regex `\"z' expected but `e' found

```
if (x>y) then a := 5 else a := 6
                ^
```

lz : Eingabe-Ende

```
import scala.util.parsing.combinator.JavaTokenParsers

object IfThenElseParser extends JavaTokenParsers {

  def stmt: Parser[Any] =
    "if" ~ "(" ~ exp ~ ")" ~ "then" ~ stmt ~ "else" ~ stmt |
    "if" ~ "(" ~ exp ~ ")" ~ "then" ~ stmt |
    ident ~ ":@" ~ exp

  def exp: Parser[Any] = term ~ rep("<" | ">") ~ term )
  def term: Parser[Any] = factor ~ rep("*" | "/" | "*" | "/") ~ term )
  def factor: Parser[Any] = floatingPointNumber | ident | "(" ~ exp ~ ")"

}

object DanglingElseApp extends App {
  println(IfThenElseParser.parseAll(IfThenElseParser.stmt, "if (x>y) then a := 5 else a := 6"))
}
```

[1.33] **parsed:**  
(((((((if~())~((x~List())~List(>~(y~List()))))~))~))~then)~((a~:=)~((5~List())~List()))~else)~((a~:=)~((6~List())~List()))

Reihenfolge ist wichtig

## Packrat-Parser

**PEG: Parsing Expression Grammar** (Bryan Ford in 2004)

Eine Alternative zu kontextfreien Grammatiken um die Syntax formaler Sprachen zu definieren

Wesentliches Konzept:

- Philosophisch: Statt Produktionsregeln werden Erkennungsregeln definiert
- Praktisch: Kein Unterschied zu einer kontextfreien Grammatik, außer dass bei Alternativen die erste passende Alternative den Text erkennt

```
stmt ::= if expr then stmt  
      | if expr then stmt else stmt
```

Diese Grammatik ist **nicht uneindeutig** in Bezug auf  
`if x>y then x =1 else x=2`

Dieser String ist schlicht **FALSCH** (es sei denn es gibt eine mit else beginnende Produktion): Die erste Regel passt und wird erkannt.

## Packrat-Parser

Parser die PEGs parsen und dabei einmal erkannte Teilstrings speichern  
(Packrats „hamster“ Futter)

Dieses Vorgehen

- erhöht den Speicherbedarf,
- beschleunigt aber das Parsen
- Und ermöglicht Linksrekursion: Die gleiche Produktion wird nicht zweimal an der gleichen Stelle im String ausprobiert.



*Packrat (Neotoma cinerea)*  
Bildquelle: Wikipedia

## Packrat-Parser

Beispiel:

```
import scala.util.parsing.combinator.JavaTokenParsers
import scala.util.parsing.combinator.PackratParsers

object PRParser extends JavaTokenParsers with PackratParsers {

  lazy val term: PackratParser[Any] =
    term ~ "+" ~ term |
    term ~ "-" ~ term |
    factor

  lazy val factor: PackratParser[Any] =
    factor ~ "*" ~ factor |
    factor ~ "/" ~ factor |
    "(" ~ term ~ ")" |
    floatingPointNumber
}

object Packrat_App extends App {
  println(PRParser.parseAll(PRParser.term, "1+3*4"))
}
```

```
[1.6] parsed: ((1~+)~((3~*)~4))
```

```
object NonPRParser extends JavaTokenParsers {

  lazy val term: Parser[Any] =
    term ~ "+" ~ term | term ~ "-" ~ term | factor

  lazy val factor: Parser[Any] =
    factor ~ "*" ~ factor | factor ~ "/" ~ factor | "(" ~ term ~ ")" | floatingPointNumber
}

object Packrat_App extends App {
  println(NonPRParser.parseAll(NonPRParser.term, "1+3*4"))
}
```

```
Exception in thread "main"
java.lang.StackOverflowError
```

# Übersicht: Parserkombinatoren in Scala

---

## Klassenübersicht

### Parsers

Basisklasse für Parser

### RegexParsers

Basisklasse für Parser die Strings parsen

bietet implizite Konversion von einem RegEx zu einer Parser der erkannte Strings parst

### JavaTokenParsers

Subklasse von RegExParsers (!) kennt die RegExe für Java Tokens

### TokenParsers

Basisklasse für Parser, die Tokens verarbeiten

### StandardTokenParsers

Basisklasse für Parser, die vordefinierte (Standard-) Tokens verarbeiten

# Übersicht: Parserkombinatoren in Scala

## JavaTokenParsers

werden verwendet wenn die lexikalischen Elemente denen von Java entsprechen

Beispiel:

```
object ExpParser extends JavaTokenParsers {

  private def exp: Parser[Exp] = chain1(term, term, addOp)

  private def addOp : Parser[(Exp, Exp) => Exp] =
    "+" ^^ { (x:Exp, y: Exp) => Plus(x,y) } |
    "-" ^^ { (x:Exp, y: Exp) => Minus(x,y) }

  private def term = chain1(factor, factor, multOp)

  private def multOp : Parser[(Exp, Exp) => Exp] =
    "*" ^^ { (x:Exp, y: Exp) => Mult(x,y) } |
    "/" ^^ { (x:Exp, y: Exp) => Div(x,y) }

  // wholeNumber is a regex defined in JavaTokenParsers
  private def factor: Parser[Exp] =
    wholeNumber ^^ { d => Const(d.toInt) } |
    ("~>exp<~)" ^^ { e => e }

  def parse(s: String) : Exp =
    phrase(exp)(new CharSequenceReader(s)) match {
      case Success(e,_) => e
      case NoSuccess(msg,_) => throw new IllegalArgumentException(
        "Parser Error '" + s + "': " + msg)
    }
}
```

# Übersicht: Parserkombinatoren in Scala

## RegexParsers

werden verwendet wenn die lexikalischen Elemente nicht denen von Java entsprechen

Beispiel:

```
object ExpParser extends RegexParsers {

  // regex definition
  def wholeNumberPattern = """"\d+""".r

  private def exp: Parser[Exp] = chain1(term, term, addOp)

  private def addOp : Parser[(Exp, Exp) => Exp] =
    "+" ^^ { (x:Exp, y: Exp) => Plus(x,y) } |
    "-" ^^ { (x:Exp, y: Exp) => Minus(x,y) }

  private def term = chain1(factor, factor, multOp)

  private def multOp : Parser[(Exp, Exp) => Exp] =
    "*" ^^ { (x:Exp, y: Exp) => Mult(x,y) } |
    "/" ^^ { (x:Exp, y: Exp) => Div(x,y) }

  // a regex may be used as parser
  private def factor: Parser[Exp] =
    wholeNumberPattern ^^ { d => Const(d.toInt) } |
    "(" ~> exp <~ ")" ^^ { e => e }

  def parse(str: String) : Exp = parseAll(exp, str) match {
    case Success(result, _) => result
    case failure : NoSuccess => scala.sys.error(failure.msg)
  }
}
```

# Übersicht: Parserkombinatoren in Scala

## StandardTokenParsers

```
object ProgParser extends StandardTokenParsers {  
  
  // definition of keywords in value lexical of StandardTokenParsers  
  lexical.reserved += ("program", "var", "value", "read", "end")  
  
  // definition of delimiters in value lexical of StandardTokenParsers  
  lexical.delimiters += ("+", "-", "*", "/", ":", "(", ")", ";")  
  
  private def exp: Parser[Exp] = chainl1(term, term, addOp)  
  
  private def addOp : Parser[(Exp, Exp) => Exp] =  
    "+" ^^ { (x:Exp, y: Exp) => Plus(x,y) } |  
    "-" ^^ { (x:Exp, y: Exp) => Minus(x,y) }  
  
  private def term = chainl1(factor, factor, multOp)  
  
  private def multOp : Parser[(Exp, Exp) => Exp] =  
    "*" ^^ { (x:Exp, y: Exp) => Mult(x,y) } |  
    "/" ^^ { (x:Exp, y: Exp) => Div(x,y) }  
  
  // numericLit is defined in StandardTokenParsers as a parser that parses numeric literals (to strings)  
  // numeric literals are tokens that are formed by sequences of digits  
  private def factor: Parser[Exp] =  
    numericLit      ^^ { digits => Const(digits.toInt) } |  
    ident           ^^ { str    => Var(str) } |  
    "read"         ^^ { name => Read } |  
    "(" ~> exp <~ ")" ^^ { e => e }  
  
  def definition: Parser[Definition] =  
    ("var" ~> ident <~ ":@" ~ (exp <~ ";") ^^ { case name ~ value => Definition(name, value) }  
  
  def program: Parser[Program] =  
    ("program" ~> rep(definition)) ~ ("value" ~> exp <~ "end") ^^ { case defs ~ value => Program(defs, value) }  
  
  // StandardTokenParsers do not have a parseAll method. parseAll is defined in RegexParsers,  
  // use phrase(program) on the tokens created by the lexer  
  def parse(str: String) : Program = {  
    val lexer = new lexical.Scanner(str) // lexical is defined in StandardTokenParsers as val lexical = new StdLexical  
    phrase(program)(lexer) match {  
      case Success(tree,_) => tree  
      case m@NoSuccess(msg,_) => println(m)  
        throw new IllegalArgumentException("Parser Error")  
    }  
  }  
}
```

werden verwendet  
wenn die  
lexikalischen  
Elemente neu  
definiert werden  
sollen.

Beispiel:

# Übersicht: Parserkombinatoren in Scala

## TokenParsers

werden verwendet wenn die lexikalische und syntaktische Ebene getrennt werden soll (Nur für Fortgeschrittene !)

Beispiel lexikalische Ebene / Tokens definieren:

```
import scala.util.parsing.combinator.token.Tokens

trait ExpTokens extends Tokens {

  sealed abstract class ExpToken extends Token

  case class NumberToken(chars: String) extends ExpToken {
    override def toString: String = "NUM_T(" + chars + ")"
  }

  case class OperatorToken(chars: String) extends ExpToken {
    override def toString: String = "OP_T(" + chars + ")"
  }

  case class LeftPToken(chars: String) extends ExpToken {
    override def toString: String = "("_T
  }

  case class RightPToken(chars: String) extends ExpToken {
    override def toString: String = ")_T"
  }
}
```

# Übersicht: Parserkombinatoren in Scala

## TokenParsers Beispiel lexikalische Ebene:

```
class ExpLexical extends RegexParsers with ExpTokens {  
  
  // define lexical structure of the tokens as regular expressions  
  private val numberPatS = ""(0|(?:[1-9][0-9]*))""  
  private val operatorPatS = ""(\+|\-|\*|/)""  
  private val leftPPatS = ""(\()""  
  private val rightPPatS = ""(\)""  
  
  private val NumberPat = numberPatS.r  
  private val OperatorPat = operatorPatS.r  
  private val LeftPPat = leftPPatS.r  
  private val RightPPat = rightPPatS.r  
  
  private val whiteSpacePat = ""\s+"".r  
  
  /** A parser that produces a token (from a stream of characters). */  
  private def token: Parser[ExpToken] =  
    NumberPat ^^ { str => NumberToken(str) } |  
    OperatorPat ^^ { str => OperatorToken(str) } |  
    LeftPPat ^^ { str => LeftPToken(str) } |  
    RightPPat ^^ { str => RightPToken(str) } |  
    failure("illegal character")  
  
  /** A parser that produces a list of tokens (from a stream of characters). */  
  private def tokens: Parser[List[ExpToken]] = rep(token)  
  
  /** A function that produces tokens form a string. */  
  def tokenize(code: String): List[ExpToken] = {  
    parse(tokens, code) match {  
      case NoSuccess(msg, next) => throw new Exception(msg)  
      case Success(result, next) => result  
    }  
  }  
} }  
  
// A scanner is just a reader for tokens  
class Scanner(src: String) extends Reader[ExpToken] {  
  import scala.util.parsing.input.{Position, NoPosition}  
  
  val tokenList = tokenize(src)  
  var p = 0  
  
  override def first: ExpToken = tokenList(p)  
  
  override def rest: Reader[ExpToken] = {  
    p = p + 1  
    this  
  }  
  
  override def atEnd: Boolean = (p == tokenList.length)  
  def pos: Position = NoPosition  
}
```

# Übersicht: Parserkombinatoren in Scala

## TokenParsers Beispiel syntaktische Ebene

```
object ExpParser extends TokenParsers {  
  val lexical = new ExpLexical  
  import lexical.{ExpToken, OperatorToken, NumberToken, LeftPToken, RightPToken}  
  
  override type Tokens = ExpTokens  
  override type Elem = lexical.Token  
  
  // Conversion to turn tokens into parsers automatically is provided by TokenParsers  
  //implicit def tokenToParser(tok: ExpToken): Parser[ExpToken] = ...  
  
  // parse number token  
  // cumbersome because there is no predefined parser for classes(!) instead for objects as above.  
  val number : Parser[lexical.Token] =  
    elem("number", _.isInstanceOf[NumberToken])  
  
  private def exp: Parser[ExpTree] = chainl1(term, term, addOp)  
  
  private def addOp : Parser[(ExpTree, ExpTree) => ExpTree] =  
    OperatorToken("+") ^^^ {(x:ExpTree, y: ExpTree) => Operation(x, Operator('+'), y)} |  
    OperatorToken("-") ^^^ {(x:ExpTree, y: ExpTree) => Operation(x, Operator('-'), y)}  
  
  private def term = chainl1(factor, factor, multOp)  
  
  private def multOp : Parser[(ExpTree, ExpTree) => ExpTree] =  
    OperatorToken("*") ^^^ {(x:ExpTree, y: ExpTree) => Operation(x, Operator('*'), y)} |  
    OperatorToken("/") ^^^ {(x:ExpTree, y: ExpTree) => Operation(x, Operator('/'), y)}  
  
  private def factor: Parser[ExpTree] =  
    LeftPToken("(") ~> exp <~ RightPToken(")") |  
    number      ^^ { (n: lexical.Token) => Number(n.chars.toInt) }  
  }  
}
```

```
def parse(code: String) : ExpTree = {  
  val scanner = new lexical.Scanner(code)  
  
  phrase(exp)(scanner) match {  
    case Success(tree,_) => tree  
    case error@NoSuccess(_,_) => println(error)  
    throw new IllegalArgumentException("Parser Error")  
  }  
}
```

---

## Quellen

- API <http://www.scala-lang.org/api/2.11.8/scala-parser-combinators/>
- M. Odersky, L. Spoon, B. Venners: *Programming in Scala*, 3<sup>rd</sup> edition
- *Parsing expression grammar*:
  - [http://en.wikipedia.org/wiki/Parsing\\_expression\\_grammar](http://en.wikipedia.org/wiki/Parsing_expression_grammar)
  - <http://bford.info/pub/lang/peg-slides/>
  - <http://bford.info/pub/lang/thesis/>
- E. Labun: *Combinator Parsing in Scala*, Masterarbeit THM: <http://labun.com/fh/ma.pdf>