

Overall Structure

$\neg <> <\cup\cup$ コンパイラ・コンパイラへの入力は、Java と同じプロセス (JLS 3.2) でトークンの列に変換される。ただし、終端記号は次のようになる。

終端記号	説明
<i>IDENTIFIER</i>	\$で始まる
予約語	\$で始まらない
セパレータ・オペレータ	以下の EBNF で使われる文字列 および <u> </u> , <u>&&</u> , <u>--</u> , <u>!!</u> , <u>**</u> , <u>++</u> , <u>??</u>
<i>CHAR</i>	Java の文字リテラル
<i>STRING</i>	Java の文字列リテラル

このドキュメントは、 $\neg <> <\cup\cup$ への入力の文法を、次の記法を用いた EBNF で示す。

メタ表現	説明
<i>Italic</i> or <i>italic</i>	非終端記号
<i>ITALIC</i>	終端記号 (シンボル)
<u>Underlined</u>	終端記号 (即値)
<i>expr1</i> <i>expr2</i>	選択
<i>expr*</i>	Kleene star
<i>expr_{opt}</i>	省略可能

トークンの列は、次の文法に従っていなければならぬ。ゴル記号 (開始記号) は、Root である。

```
Root ::= ParserDeclaration
       ConstructorScopeopt
       definition*
ParserDeclaration ::= $protectedopt $parser JavaName ;
JavaName ::= IDENTIFIER ( _ IDENTIFIER )*
ConstructorScope ::= $protected $constructor ;
definition ::= SubtokenDefinition
             | TokenDefinition
             | AliasDefinition
             | TypeDefinition
```

$\neg <> <\cup\cup$ は Java のソースファイルを 1 つ出力し、それは多数のネストしたタイプを含むトップレベル・クラスを 1 つ定義する。トップレベル・クラスの名前は、ParserDeclaration によって決められる。ParserDeclaration に \$protected が指定されていれば、出力されるクラスはデフォルトスコープ (パッケージスコープ) になり、そうでなければ public になる。ConstructorScope は、出力されるトップレベル・クラスのコンストラクタを、デフォルトスコープ (パッケージスコープ) にする。definition は、出力されるトップレベル・クラスの詳細を定義する。

Lexical Analyzer

SubtokenDefinition ::=

\$subtoken IDENTIFIER \equiv tokenExpression ;

TokenDefinition ::=

\$white_{opt} \$token

IDENTIFIER (\equiv tokenExpression)_{opt} ;

出力されるトップレベル・クラスは、字句解析のためのインターフェイスと、デフォルトの実装を含む。デフォルトの実装は、入力された文字列の先頭から、終端記号のどれかが最長一致でマッチする文字列をトークン (終端記号のインスタンスとも呼ぶ) として切り出すことを繰り返す。

1 つの TokenDefinition は、1 つの終端記号を定義する。終端記号は、tokenExpression がマッチする文字の列にマッチする。ただし、tokenExpression が省略されていた場合、その TokenDefinition によって定義される終端記号は、どの列にもマッチしない (ユーザ定義の字句解析器のためだけに使われる)。\$abstract でない TypeDefinition/AliasDefinition の expression 中の STRING も終端記号を定義する。この終端記号は、文字列リテラルが表す文字列にマッチする。

もし、終端記号が \$white として定義されていれば、そのインスタンスをホワイト・トークンと呼ぶ。ホワイト・トークン

は、構文解析に際して無視されるので、ホワイトスペースやコメントを扱うのに有用である。

SubtokenDefinition は、tokenExpression に対して名前を与える。この名前は、tokenExpression の中で使うことができる。tokenExpressions は次の表で与えられる。

P.	tokenExpression	マッチする文字列
6	<i>expr1</i> <i>expr2</i>	どちらかがマッチする文字列
5	<i>expr1</i> & <i>expr2</i>	両方がマッチする文字列
	<i>expr1</i> - <i>expr2</i>	前者がマッチし、後者がしない文字列
4	<i>expr1</i> <i>expr2</i> ...	マッチした文字列をつなげた文字列
3	<u>_</u> <i>expr</i>	マッチしない文字列
2	<i>expr</i> *	0 回以上の繰り返し
	<i>expr</i> +	1 回以上の繰り返し
	<i>expr</i> ?	0 か 1 回の繰り返し
1	<u>[</u> <i>expr</i> <u>]</u>	0 か 1 回の繰り返し
	<u>(</u> <i>expr</i> <u>)</u>	<i>expr</i> がマッチする文字列
	<i>CHAR</i>	<i>CHAR</i> が表す文字
	<i>CHAR</i> .. <i>CHAR</i>	その範囲にある文字
	<i>STRING</i>	<i>STRING</i> が表す文字列
	<i>IDENTIFIER</i>	(サブ) 終端記号がマッチする文字列

Syntax Analyzer

AliasDefinition ::= IDENTIFIER \equiv expression ;

TypeDefinition ::= modifiers IDENTIFIER supertypes_{opt}
{ expression }

modifiers ::= (\$protected | \$private)_{opt} \$abstract_{opt}
| \$parsable
| \$protected-parsable \$protected_{opt}

supertypes ::= \rightarrow TypeName (& TypeName)*

TypeName ::= IDENTIFIER

InlineExpression ::= TypeDefinition

出力されるトップレベル・クラスは、字句解析器が出力するトークンの列を構文解析する構文解析器を含む。文法は、拡張された EBNF で表現される。1 つの TypeDefinition か 1 つの AliasDefinition が、1 つのプロダクションを定義する。IDENTIFIER は、定義される非終端記号の名前を表し、expression が、プロダクションの右辺をあらわす。TypeDefinition は、expression の中で、InlineExpression としても現れる。

expression は次のように定義される。

P.	expression	マッチするトークン列
5	<i>expr1</i> <i>expr2</i>	いずれかがマッチする列
4	<i>expr1</i> <i>expr2</i> ...	マッチする列をつなげたもの
3	<i>expr</i> * <i>expr</i> + <i>expr</i> ? <i>expr</i> / TypeName	0 回以上の繰り返し 1 回以上の繰り返し 0 か 1 回の繰り返し <i>expr</i> がマッチする列 (ラベルの型を制御するのに使われる)
2	IDENTIFIER : expr	expr がマッチする列 (labeled expression)
	\$label : expr	expr がマッチする列 (labeled expression)
1	<u>[</u> <i>expr</i> <u>]</u> <u>(</u> <i>expr</i> <u>)</u> \$embed <u>(</u> <i>expr</i> <u>)</u> IDENTIFIER STRING InlineExpression	0 か 1 回の繰り返し <i>expr</i> がマッチする列 <i>expr</i> がマッチする列 <i>expr</i> がマッチする列 (エイリアスをその式で置き換える) 終端・非終端記号がマッチする列 その終端記号 その非終端記号がマッチする文字列

構文解析器は、最初に具象構文木 (CST; concrete syntax tree) を構築する (Example 参照)。トークン (終端記号のインスタンス) が構文木の葉になり、非終端記号のインスタンスが構文木のノードを作る。ノードは、ラベル付けされた子を持つ。label: expression の形式の labeled expression は、expression に含まれる終端・非終端記号のインスタンスが、label によってラベル付けされることを表す。1 つのインスタンスが複数のラベルによってラベル付けされても構わないし、1 つのラベルが

複数のインスタンスをラベル付けしても良い。*expression*の中に、同じラベルが字句的に複数回存在しても良い。

その後、構文解析器は、具象構文木からノードを取り除くことで、**抽象構文木**(AST; abstract syntax tree)を構築する。*AliasDefinition*で定義される非終端記号(エイリアス)のインスタンスであるノードが、全て取り除かれる。取り除かれたノードの子は、取り除かれたノードの親の子になる。取り除かれたノードに\$labelによってラベル付けされた子が存在した場合、\$labelを取り除かれたノードをラベル付けしているラベルで置き換える。取り除かれたノードのどの子も\$labelによってラベル付けされていない場合、全ての子が取り除かれたノードをラベル付けしているラベルによってラベル付けされる。

抽象構文木はJavaのオブジェクトによる木構造で表される。トークンは、入れ子のインターフェイスTokenのインスタンスで表される。葉以外のノードは、そのノードが具象構文木においてインスタンスであった非終端記号と同じ名前を持つネストしたインターフェイスのインスタンスで表される。そのインターフェイスは、ラベルと同名で、引数の無いメソッドを持つ。メソッドの戻り値は、そのラベルによってラベル付けされている子(高々1つの子しかラベル付けしない場合)、あるいは子のリスト(複数の子をラベル付けする可能性がある場合)である。戻り値の静的型は、前者の場合ラベル付けされる可能性のある子に共通の型で、公平に最も限的なものになる。後者の場合、最も限的な共通の型の配列かjava.util.Listになる。

*supertypes*は、ネストしたインターフェイスの継承関係を設定する。*TypeName*は、*TypeDefinition*によって定義された非終端記号の名前で無ければならない。もし、*supertypes*が無ければ、そのネストしたインターフェイスは、Nodeのサブインターフェイスになる。Tokenもまた、Nodeのサブタイプである。

もし、非終端記号が\$parsableと定義されていれば、出力されるトップレベル・クラスは、その非終端記号をゴール記号(開始記号)とする文法を構文解析する、様々な引数を伴ったpublicなメソッドを持つ。非終端記号が\$protected-parsableと定義されていれば、同様だがprotectedなメソッドがoutputされる。

もし、非終端記号が\$protectedか\$privateと定義されていれば、その非終端記号と同名のネストしたインターフェイスは、protectedかprivateになる。そうでない場合、そのネストしたインターフェイスはpublicになる。

もし非終端記号が\$abstractと定義されていれば、その非終端記号はネストしたインターフェイスを生成するが、\$abstractでないTypeDefinition/AliasDefinitionのexpression中に現れることはできない。

Example

```
$parser parser.Parser;
$protected $constructor;

$token INTEGER = '0'..'9'+;
$white $token WHITE_SPACES = ( ' ' | '\t' )+ ;

$parsable Example { expr:expr }

$abstract Expr { }
expr = term | Add | Sub ;
Add -> Expr { op1:expr "+" op2:term }
Sub -> Expr { op1:expr "-" op2:term }
term = prim
| Mul -> Expr { op1:term "*" op2:prim }
| Div -> Expr { op1:term "/" op2:prim } ;
prim = "(" $label:expr ")" | $label:Num ;
Num -> Expr { value:INTEGER }
```

このソースから次のような出力が得られる。

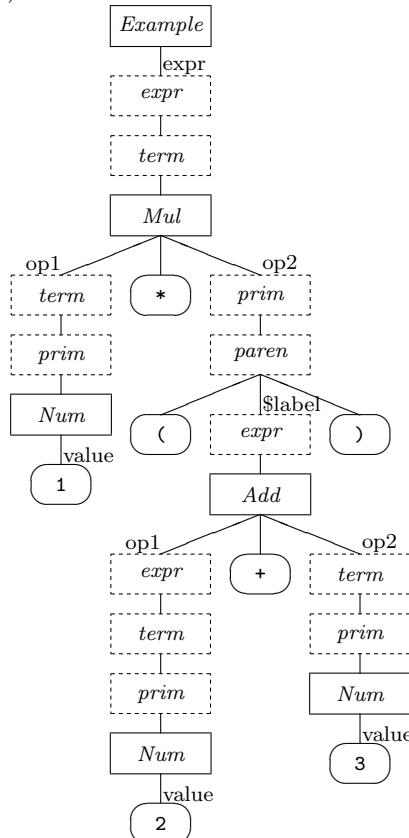
```
package parser;
public class Parser {
    Parser() { ... }
```

```
public static abstract class LexicalAnalyzer { ... }
protected LexicalAnalyzer
    createLexicalAnalyzer(...) { ... }
public static interface Node {
    List getChildNodes(); ...
}
public static interface Token extends Node {
    String getImage();
    int getLine(); int getColumn(); ...
}
public Example parseExample(File file) { ... }
public Example parseExample(LexicalAnalyzer la) {
    ...
}

public static interface Example extends Node {
    Expr expr(); ...
}
public static Expr extends Node { }
public interface Add extends Expr {
    Expr op1(); Expr op2(); ...
}
...
}
```

詳細は、出力されたプログラムのjavadocコメントへ記述されている。

$1 * (2 + 3)$ を表す具象構文木は、



点線で囲まれたノードを取り除いて作られた抽象構文木は、

