



TIKRIT UNIVERSITY  
COLLEGE OF COMPUTER SCIENCE AND MATHEMATICS  
DEPARTMENT OF COMPUTER SCIENCE

SUBJECT OF COMPILER1  
DATE OF ISSUE: 2024 - 2025  
CLASS: 3TH STAGE  
SEMESTER 1  
LECTURE NO.: 2



**PREPARED BY**

Lecturer:  
**Mohanad Dawood Al-Roomi** &

Assistant Lecturer:  
**Luay Ibrahim Klalif**

# Language-processing system (Compilation):

## ➤ WHAT IS THE PROBLEM?

- A computer's CPU can understand and execute directly language written software of Machine language (0 , 1) only.
- Computer programs implemented in programming languages with the help of software programs called Language - processing system. (compilation).
- In general, a compiler as a single box that converted a source program into a semantically equivalent target program.

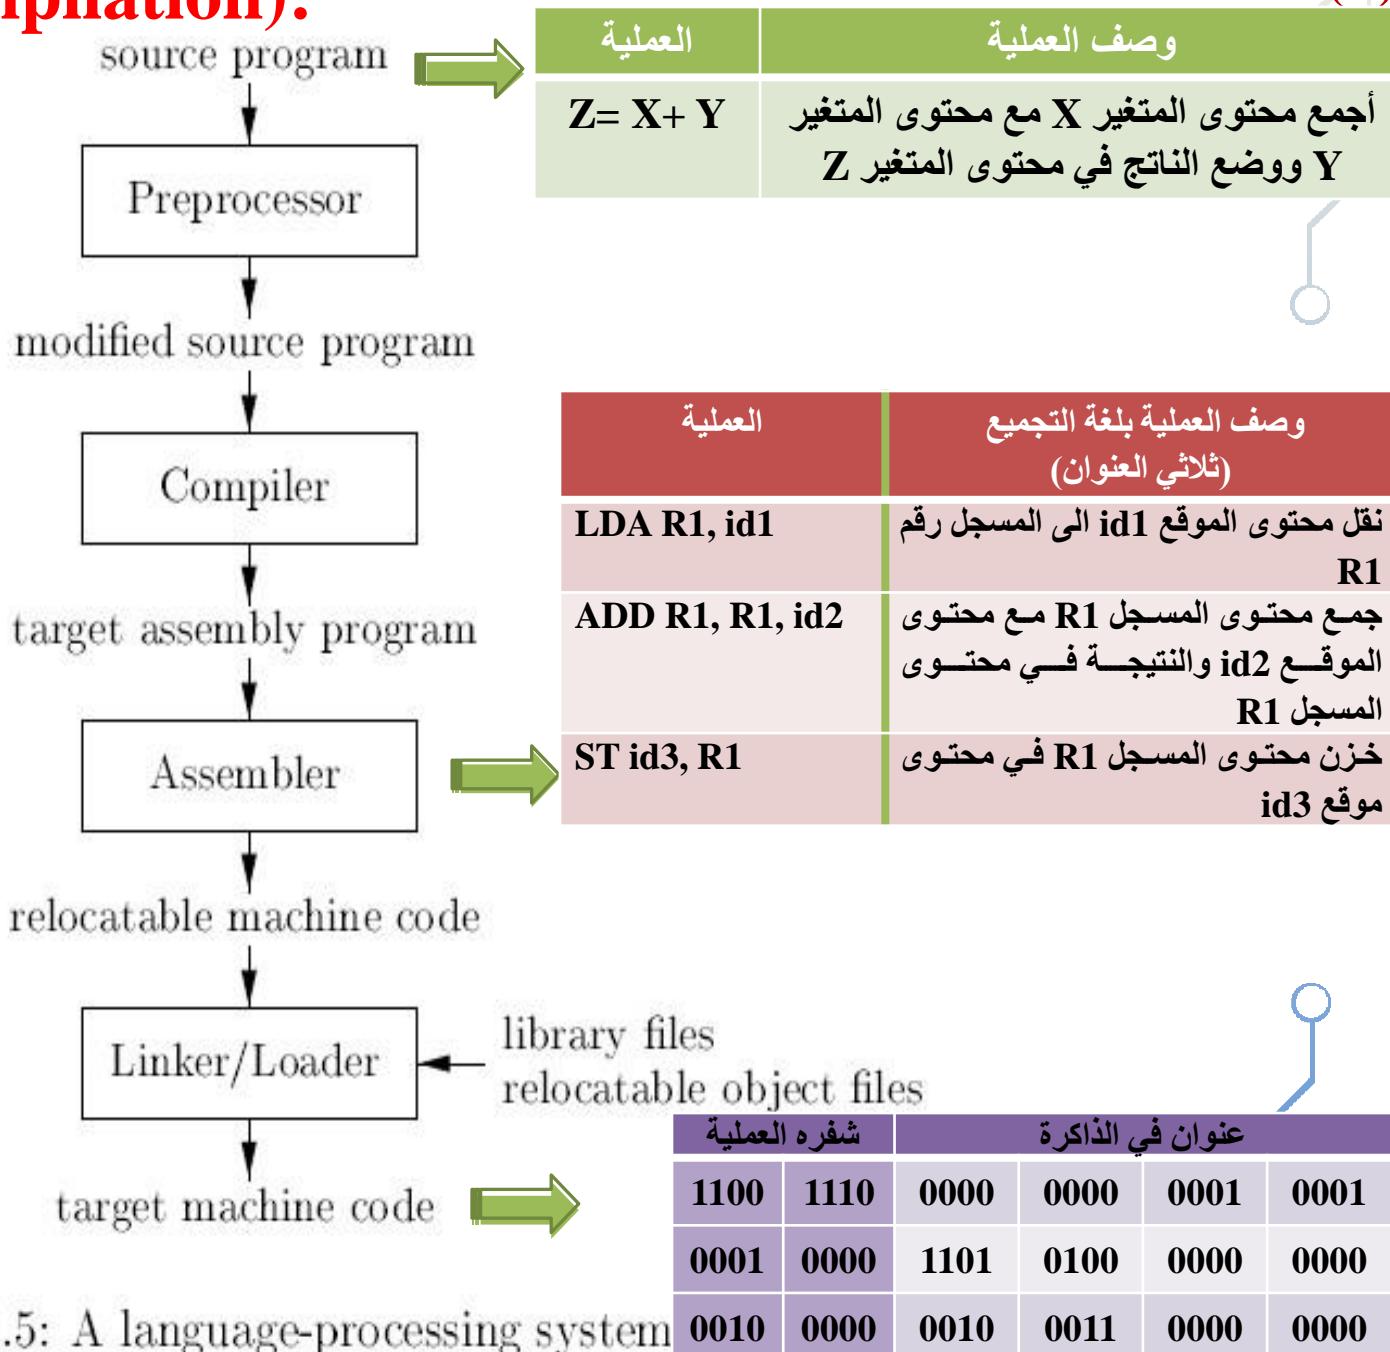


Figure 1.5: A language-processing system

## Language-processing system (Compilation):

It is several programs may be required to create an executable target program are:

### A preprocessor:

is a program that processes source language to produce a modified source program that is used as input to another program. The task of collecting the source program is sometimes entrusted to a separate program.(File Inclusion.) The preprocessor may also expand shorthand's, called macros, into source language statements.(Macro processing.)

### A compiler

The modified source program is then fed to a compiler. The compiler may produce an assembly-language program as its output.

### An assembler

The assembly language is then processed by a program called an assembler that produces relocatable machine code as its output.

### A Linker / Loader:

Large programs are often compiled in pieces, so the relocatable machine code may have to be linked together with other relocatable object files and library files into the code that actually runs on the machine. The linker resolves external memory addresses, where the code in one file may refer to a location in another file. The loader then puts together all of the executable object files into memory for execution.

# PHASES OF COMPILER

The following are the phases of the compiler:

## Main phases:

1. Lexical analysis phase. (الفحص المفردات) Analysis
2. Syntax analysis phase. (التحقق من القواعد اللغوية) Analysis
3. Semantic analysis phase. (التحقق من المعانٍ) (الدلالي) Analysis
4. Intermediate code generation phase. (طور توليد الشفرة الوسطية)
5. Code optimization phase. (طور تحسين الشفرة) Synthesis
6. Code generation phase. (طور توليد الشفرة) Synthesis

## Sub-Phases:

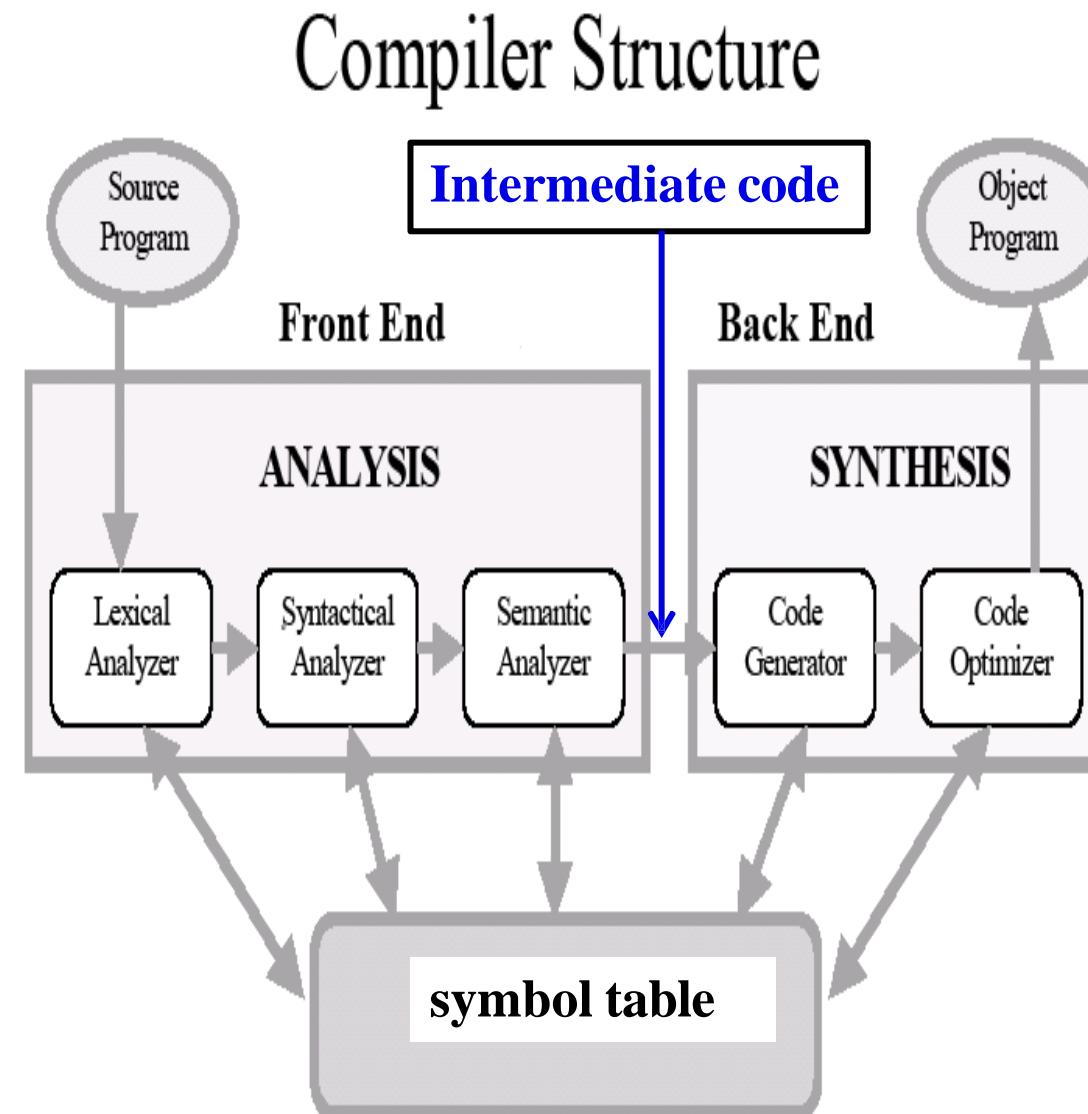
1. Symbol table management. (ادارة جدول الرموز)
2. Error handling. (معالجة الخطأ)

# The Structure of a Compiler

There are two parts to this to the compiler:

## 1. Analysis: التحليل

- The analysis part breaks up the source program into constituent pieces and imposes a grammatical structure on them.
- It then uses this structure to create an intermediate representation of the source program.
- It collects information about the source program and stores it in a data structure called a symbol table.
- detects some errors (either syntactically ill formed or semantically unsound) in the source program.



## 2. Synthesis: التوليف (التركيب)

The synthesis part constructs the desired target program from the intermediate representation and the information in the symbol table.

- The symbol table, which stores information about the entire source program, is used by all phases of the compiler.
- The analysis part is often called the front end of the compiler; the synthesis part is the back end.

# PHASES OF COMPILER

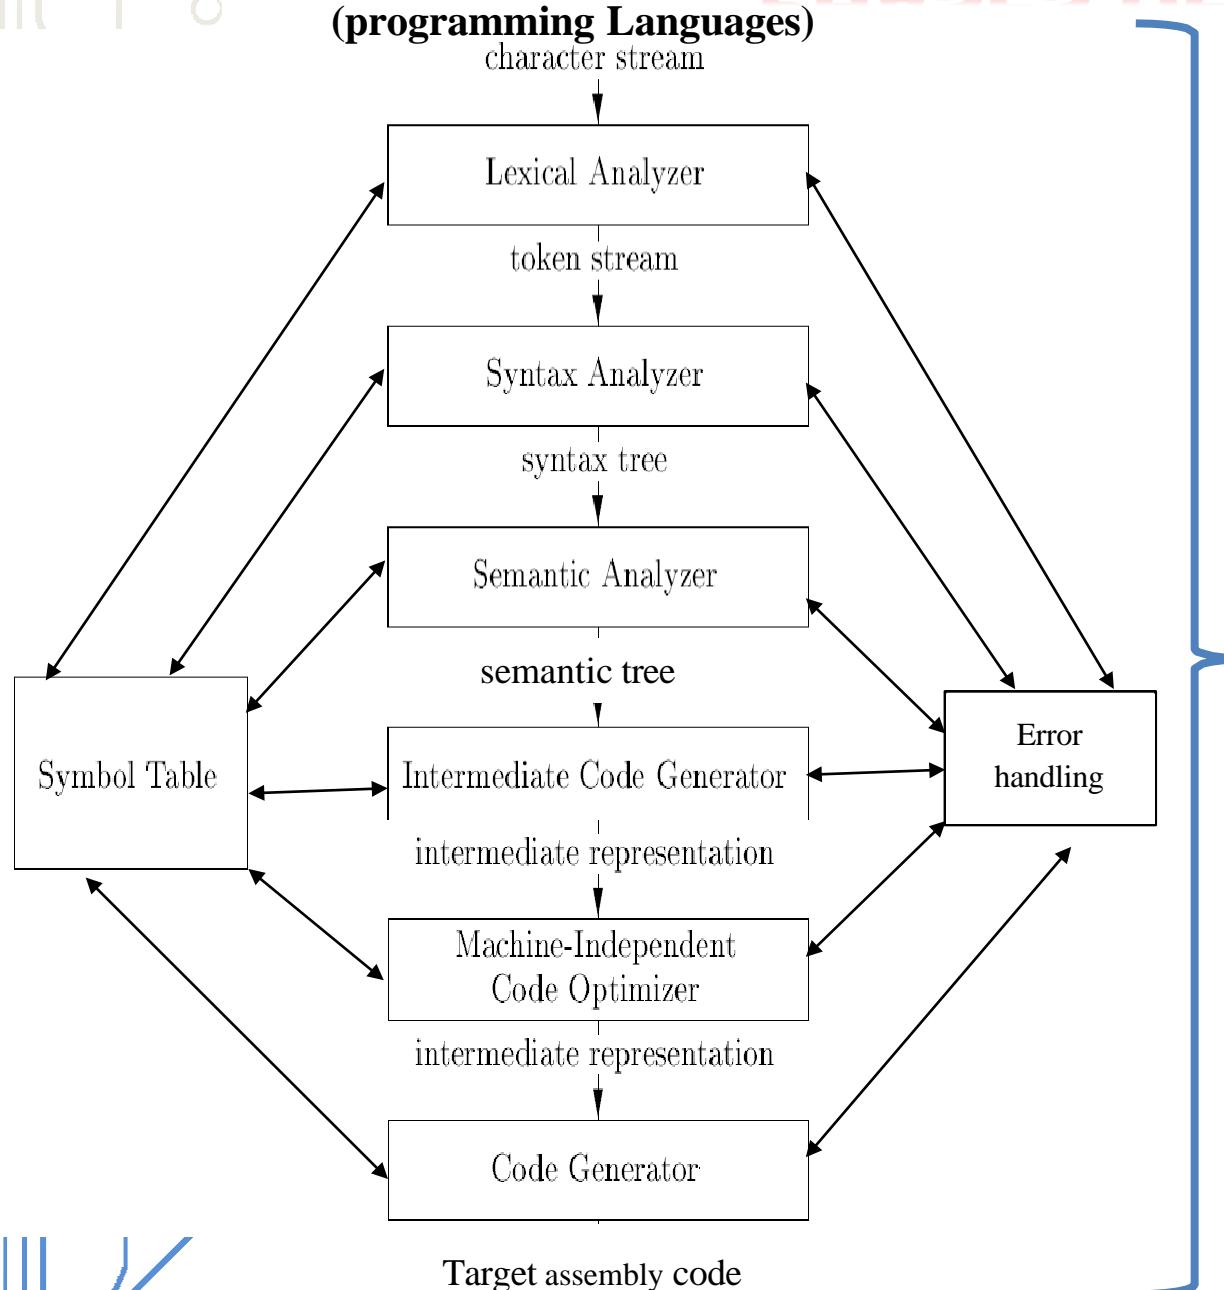


Figure 1.5: A language-processing system

## Lexical Analyzer phase:

Software system and first phase of the compiler. It reads and scans the input characters (ASCII) making up the source program and groups the characters into meaningful sequences called lexemes and it produces as output tokens table (token-name; attribute-value), symbol table and tokens stream. It sends the tokens stream to the parser. This phase identifies errors according to a misspellings of lexeme.

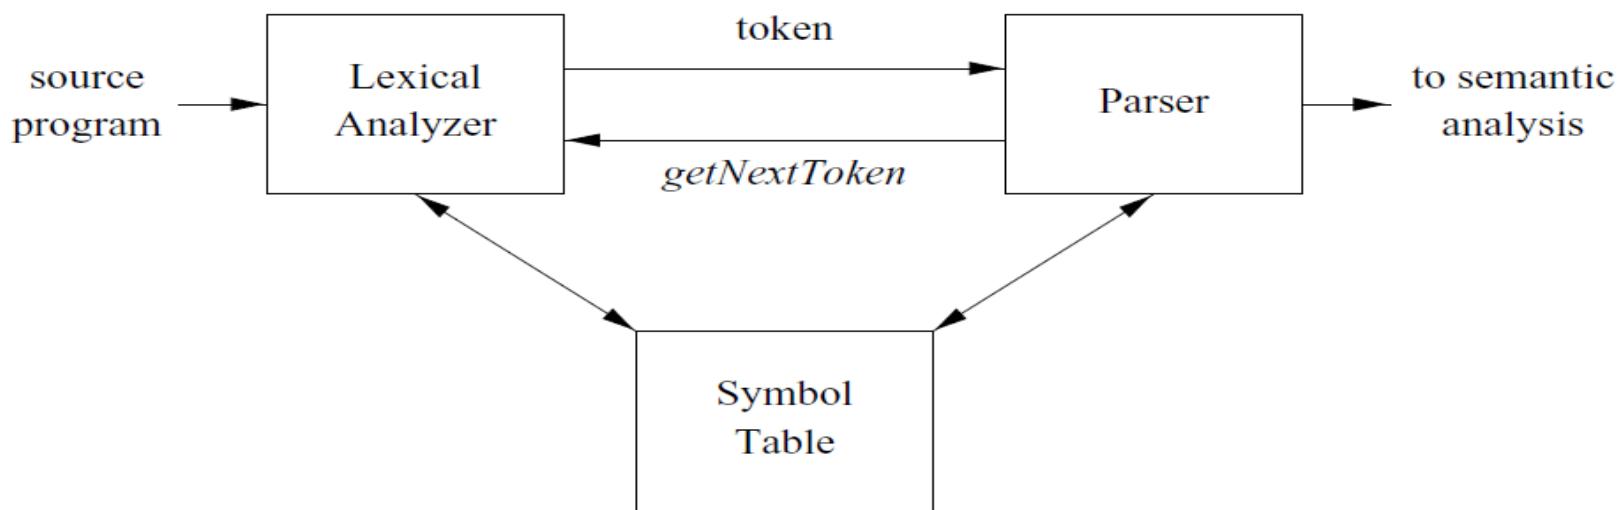


Figure 3.1: Interactions between the lexical analyzer and the parser

## The Role of the Lexical Analyzer

- (1) The main task of the lexical analyzer is **to read** the input characters of the source program, **group them** into lexemes, and **produce** as output a sequence of tokens for each lexeme in the source program. The stream of tokens is **sent to** the parser for syntax analysis.
- (2) When the lexical analyzer **discovers** a lexeme constituting an identifier, it **needs to enter** that lexeme into the symbol table.
- (3) There are **suggested** interactions between the lexical analyzer and the symbol table. When, the parser call the lexical analyzer to suggest by the get **NextToken** command, causes the lexical analyzer to read characters from its input until it can identify the next lexeme and produce for it the next token, which it **returns to the parser**.
- (4) One such task is stripping out comments and whitespace (blank, newline, tab, and perhaps other characters that are used to separate tokens in the input).
- (5) Another task is correlating error messages generated by the compiler with the source program. For example, the lexical analyzer may keep track of the number of newline characters seen, so it can associate a line number with each error message.
- (6) If the source program uses a macro-preprocessor, the expansion of macros may also be performed by the lexical analyzer.

## The Role of the Lexical Analyzer

(9)

Sometimes, lexical analyzers are divided into a cascade of two processes:

- (a) Scanning consists of the simple processes that do not require tokenization of the input, such as deletion of comments and compaction of consecutive whitespace characters into one.
- (b) Lexical analysis proper is the more complex portion, which produces tokens from the output of the scanner.

## The Role of Lexical analyzer phase

نفترض أن لدينا برنامج المصدر (source program) المكتوب بواسطة لغة C++. كيف يتم تحليل البرنامج المصدر من قبل طور تحليل الفقرات (Lexical analysis phase (parser)) لنميرها إلى طور تحليل القواعد اللغوية (العرب) (Syntactic analysis phase (parser))؟ وكيف يتم تصحيح أخطاء طور تحليل الفقرات أن وجدت قبل نميرها إلى طور العرب.

عندما نقوم بالضغط على مفتاح تنفيذ البرنامج (Run) يعني أننا نقوم بالطلب من المترجم (Compiler) بترجمة البرنامج المدرسي والمكتوب بلغة C++ وبما ان طور تحليل الفقرات - المفردات- (Lexical analyzer) هو اول اطوار المترجم (Compiler) والذي يقوم بصورة عامة بعملية المسح والقراءة لـ (source program) وتحويله الى (token streams) وهي كما يلى:

1. يقوم بعملية بمسح وقراءة رمز بعد رمز (Character by Character) للبرنامج المدرسي (والمكتوب بشكل رموز شفرة ASCII) بأكمله وخرقه في ذاكرة مستقلة كما هو مكتوب دون تغيير أو حذف او تعديل للاستفادة منه في تحديد موقع الخطأ اذا تطلب ذلك (It can associate a line number with each error message).

2. ضغط الفراغات المتسلسلة في فراغ واحد (Compaction of consecutive whitespace characters into one).

(11)

## The Role of Lexical analyzer phase

.٢

حذف التعليقات (Deleting comments) وكما يلي:

A. يهمل طور تحليل الفقرات الرمزين المتتاليين // وما بعدهما من جملة التعليقات الى نهاية السطر لا يقوم بتحليل او تقطيع رموزهما ولكن تبقى مخزونه في البرنامج المصدري الاصلی كما هو مكتوب.

// this is a single-line comment

B. لكن اذا كان اكثرا من سطر نستخدم

/\* this is a  
multi-line  
comment \*/

.٤

ثم يقوم بـ تقطيع وتجمیع (characters) المحسورة بين كل فراغین (Two blank spaces) ومن اليسار الى اليمين مع بعضها وانتاج Lexeme (وهو اصغر مفردة في اللغة ما ربما يتكون من رمز شفرة ASCII واحد او اکثر). وهكذا يعمل لجميع رموز برنامج المصدر.

.٥

تعطى جميع (Lexemes) في البداية نوع بياني واحد هو characters لذلك المشكلة تكمن في كيفية تحديد قيمة هذه الـ (lexemes) وجعل المترجم يتعرف على قيمتها البيانية.

.٦

يرسل كل الـ (lexeme) الى A macro-preprocessor ليقوم بالتحقق من قيمتها وانتاج (Token) له حسب قواعد الماكروية (برامجه مخزنها مسبقا وفق قواعد اللغة المراد العمل في مجالها) التي تتعرف عليها وخرنها في (Token table). كل Token يتكون من (token- attribute) & (token- name).

# The Role of Lexical analyzer phase

## Table of operation description

Operation	Description	Meaning
+	OP_ADD	addition
-	OP_SUB	subtraction
*	OP_MUL	multiplication
/	OP_DIV	division
=	Op_ASSIGN	assignment
<	OP_LT	less than
>	Op_GT	greater than
<=	OP_LE	less or equal
>=	OP_GE	greater or equal
==	OP_EQ	equal
!=	Op_NOT EQ	not equal
&&	OP_AND	and
	OP_OR	or
!	OP_NOT	not

## 8. انواع القواعد المايكرولوجية:

.Keywords A. القاعدة المايكروية المسئولة عن تحديد كلمات المفاتيح مثل while ، for ، main ، if

**B. القاعدة المايكروية المسئولة عن تحديد المعرفات** مثل `x` ، `y` ، `line1` ، `x1` ، ...

C. القاعدة المايكروية المسؤولة عن تحديد الارقام  
M 6E-4 , 10.55E+6 , 72.4E10 , 3.542 , 3.5

D. القاعدة المايكروية المسؤولة عن تحديد العوامل Operators

## أ. العوامل الحسابية / ، \* ، - ، +.

## ii. العوامل الارتباط

### iii. العوامل المنطقية .(.) Not ، (||)OR ، (&&) And

## Assignment = علامة الاحلال .iv

**العوامل المركبة** .v ++ , -- , | = , & = , > = , > = , % = , / = , \* = , - = , + = .

**E. القاعدة المايكرورية المسؤولة عن تحديد الفواصل والتنقيط** .Punctuations مثل ( ، ) ، { ، } ، ، ف ، . ، : ، ' ، [ ، ] ، " ، ،

F. القاعدة المايكرية المسئولة عن تحديد الحرفي Literal (أي شيء محصور بين علامتي الاقتباس الثانية " " ). مثل "Student".

# H.W.4.3. The macro-preprocessor

(13)

< Keyword > قاعدة مايكروية تختبر الكلمات المحفوظة

< Identifier > قاعدة مايكروية تختبر المعرف

< Number > قاعدة مايكروية تختبر الرقم بصورة عامة

< Operator > قاعدة مايكروية تختبر العمليات الحسابية

< Punctuation > قاعدة مايكروية تختبر الفاصلة والتنقيط

< Literal > قاعدة مايكروية تختبر الجملة بين علامتي التنصيص

Main (Algorithm)

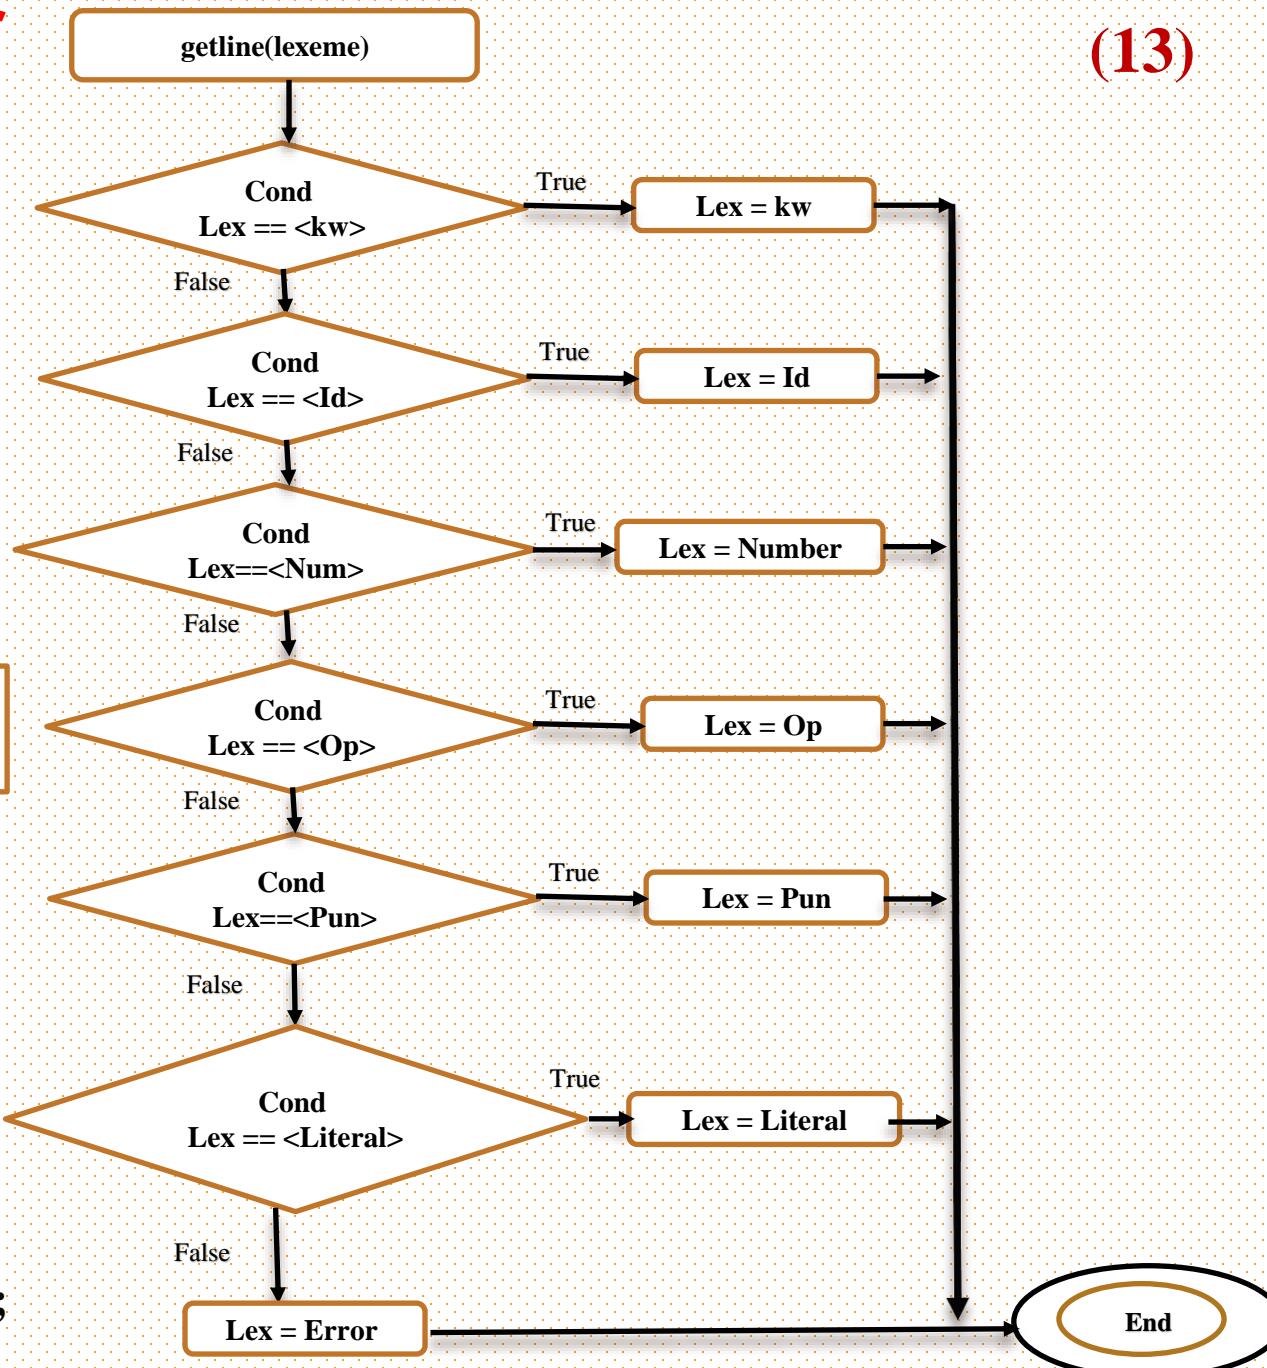
getline(lexeme);

التسلاسل (K.W.) وبعد ID هنا مطلوب

```

if (lexeme == < Keyword >) then lexeme = K.W;
else if (lexeme == < Identifier >) then lexeme = Id;
else if (lexeme == < Number >) then lexeme = number;
else if (lexeme == < Operator >) then lexeme = Op;
else if (lexeme == < Punctuation >) then lexeme = Pun;
else if (lexeme == < Literal >) then lexeme = Literal;
else lexeme = error;

```



(14)

## The Role of Lexical analyzer phase

٩. يقوم كذلك بإنشاء جدول الرموز (Symbol table) وهو هيكل بياني يحتوي على التسلسل (Sq.) و (Token-name) والذى يضع فيه الـ (Lexeme) عندما يجد بان الـ (Id) يشير الى معرف (Id) فانه يقوم بخزن اسم النموذج (Token-name) في جدول الرموز (Symbol Table). واعطاه تسلسل ولا يقوم بخزنه مرة ثانية عندما يتكرر نفس (Id) في برنامج المصدر وإنما يشير الى موقعه في (Token Table)، أما حقل (Types) يبقى فارغ في هذه المرحلة.
١٠. ثم يقوم Lexical analyzer بإنشاء هيكل بياني (Tokens stream) يوضع فيه اسماء - النماذج (Token-name) حسب ترتيب ظهورها في الجدول الفقرات (Tokens table) باستثناء المعرف بدل ان يضع اسم النموذج بوضع بدلا عنه نوع - النموذج (Token - attribute value) الموجود في جدول الفقرات (Tokens-table) وتسلسل ظهور المعرف الموجود في جدول الرموز (Symbol table).

Definition an identifier of tokens stream, that is consist of two parts are: token – attribute of this identifier in token table and sequence of this identifier in symbol table.

١١. ثم يمرر هذا الهيكل البياني (Tokens stream) الى (syntax analysis phase) الى

(15)

## The Role of Lexical analyzer phase

- اذا وجد **Lexical analyzer phase** بأن (Lexeme) لا ينتمي الى اي من القواعد المايكروية سوف يقوم بارسال رسالة خطأ الى المستخدم ويخبره بأن **الـLexeme** الحالي غير معروف بالنسبة **إليه** (Unknown identifier) وتحديد السطر الذي يقع فيه **الـLexeme** موضع الخلاف ليقوم المستخدم بتصحيح **الـLexeme** في البرنامج المصدري الاصلي الموجود على الشاشة الادخال.
- أما الأخطاء الأخرى الموجودة في البرنامج المصدر الاصلي (أخطاء تركيب الفقرات أو أخطاء المعاني **syntactically ill formed or semantically unsound**) فهو غير مسؤوال عنها في هذه المرحلة.
- الأخطاء التي يكتشفها هذا الطور تكون محددة لأنه لا يكتشف الأخطاء المتعلقة بتركيب الفقرات فعندما يصادف فقرة لا تنتمي الى اي نموذج يقوم بإصدار رسالة خطأ.

Ex1: int x x x ;

سوف لن تظهر رسالة خطأ

Token Table	
اسم الفقرة	نوع الفقرة
int	K.W
x	Id
x	Id
x	Id
;	Pun

Ex2:

int @x ;

Unknown identifier

سوف تظهر رسالة خطأ

(16)

## The Role of Lexical analyzer phase

مخرجات طور تحليل الفقرات هي:

**الجدول الأول**: يسمى بجدول (Lexemes table) توضع به كل (Lexemes) التي تم تقطيعها بالاعتماد على الفراغ بعد دمج الفراغات المتعاقبة في واحد وحذف التعليقات.

**الجدول الثاني**: يسمى جدول الفقرات (المفردات - النماذج) (Tokens table) تدرج فيه كل فقرات البرنامج مع تحديد نوع كل فقرة.

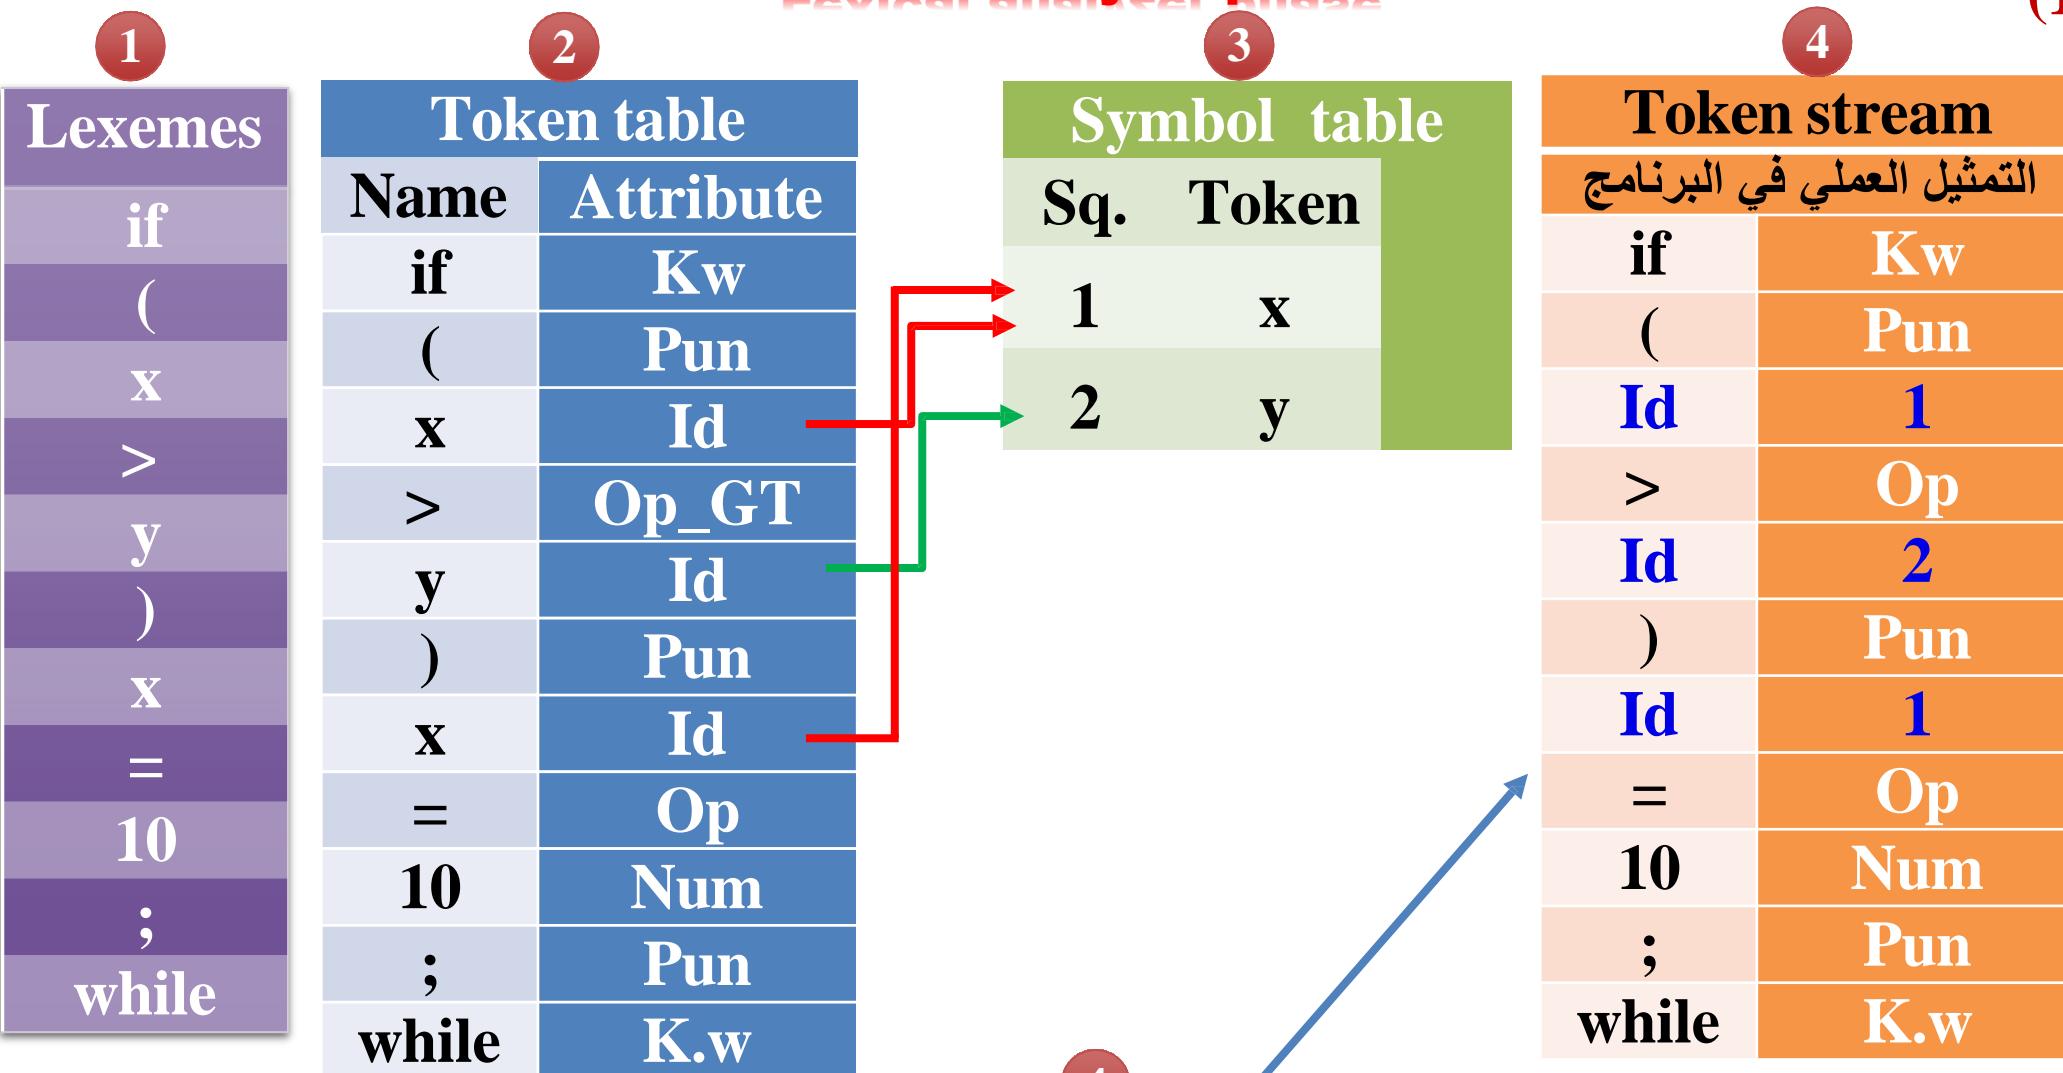
**الجدول الثالث**: هو جدول الرموز (Symbol table) حيث يفتح مدخل لكل معرف عند اول ظهور له في جدول النموذج وعند تكرار ظهور المعرف يتم عمل مؤشر الى مدخله في جدول الرموز.

**سلسلة النماذج**: وهي هيكل بياني (Tokens stream) يوضع فيه اسماء - النماذج (name-token) حسب ترتيب ظهورها في الجدول الفقرات (Tokens table) باستثناء المعرف بدل وضع اسم النموذج يوضع بدلاً عنه نوع - النموذج (attribute value) الموجود في جدول الفقرات (Tokens-table) وتسلسل ظهور المعرف الموجود في جدول الرموز (Symbol table).

# Lexical analyzer phase

**Source  
program**

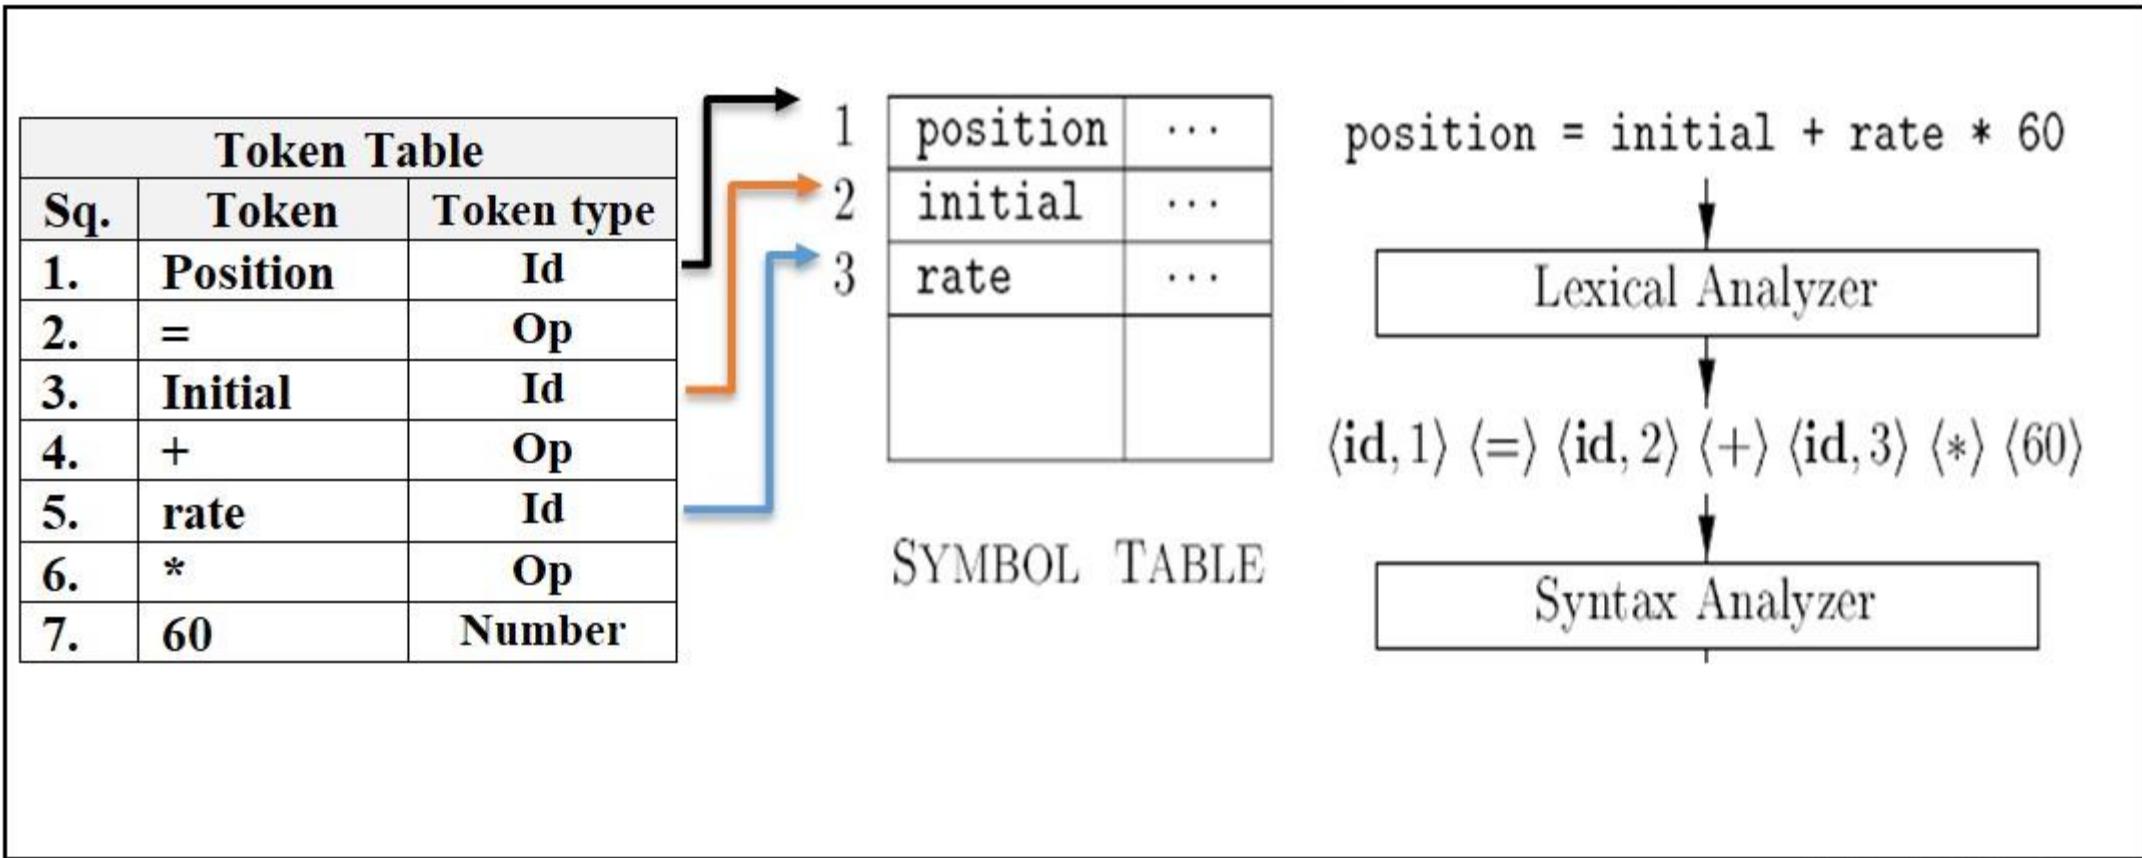
**Ex.1:**  
**if ( x > y )**  
**x = 10 ;**  
**while ...**



**التمثيل النظري على الورق:**

**<if,k.w><(,pun><Id,1> <,>,Op\_GT> <Id,2> <),pun><Id,1> <=,Op\_Assign.>**  
**<10,Num><,pun>< while,k.w>**

## Ex.2:



Solution (1): Lexemes before correction?EXAMPLE 3

If we have part from the source program by C++ in below. How to analyze it by the lexical analyzer to pass on to the syntax analyzer. Find the following:

- (1) Lexemes before correction?
- (2) Corrections in the source program those the lexical analyzer phase?
- (3) Lexemes after correction.
- (4) Token table.
- (5) Symbol table.
- (6) Tokens stream.

```

1. int main( )
2. {
3.     int x , Ahmad , float y
4.     char Array [ 10 , 10 ] ;// Array is string.
5.     x_y :=      5 ;
6.     switch ( ch )
7.     case 0 : for ( int i = 0 ; i <= 9 ; I ++
8.     Array [ i ] = 8i + yx * * @x ;
9.     Cout <<< "ahmad" ;
10.    print << Ahmed
11. }
```

Sq.	Lexemes
1.	int
2.	main
3.	(
4.	)
5.	{
6.	int
7.	x
8.	,
9.	Ahmad
10.	,
11.	float
12.	y
13.	char
14.	Array
15.	[
16.	10
17.	,
18.	10
19.	]
20.	:
21.	x_y
22.	:=
23.	5
24.	;
25.	switch
26.	(
27.	ch
28.	)
29.	case
30.	0
31.	:
32.	for

Sq.	Lexemes
33.	(
34.	int
35.	i
36.	=
37.	0
38.	;
39.	i
40.	<=
41.	9
42.	;
43.	I
44.	++
45.	Array
46.	[
47.	i
48.	]
49.	=
50.	8i
51.	+
52.	yx
53.	*
54.	*
55.	@x
56.	:
57.	Cout
58.	<<<
59.	"ahmad"
60.	;
61.	print
62.	<
63.	<
64.	Ahmed
65.	}

### Source program before correction

```

1. int main ( )
2. {
3.     int x , Ahmad , float y
4.     char Array [ 10 , 10 ] ; // Array is string.
5.     x_y := 5 ;
6.     switch ( ch )
7.     case 0 : for ( int i = 0 ; i <= 9 ; I ++
8.         Array [ i ] = 8i + yx * * @x ;
9.         Cout << "ahmad" ;
10    print << Ahmed
11 }

```

### Source program after correction

```

int main ( )
{
    int x , Ahmad , float y
    char Array [ 10 , 10 ] ; // Array is string.
    x_y = 5 ;
    switch ( ch )
    case 0 : for ( int i = 0 ; i <= 9 ; I ++
        Array [ i ] = i + yx * * x ;
        Cout << "ahmad" ;
        print << Ahmed
}

```

### Solution (2): Corrections in the source program those the lexical analyzer phase

الأخطاء التي سوف يكتشفها طور تحليل الفقرات (Lexical analyzer) (بعد ما يقوم بسماع وقراءة البرنامج المصدري في هذا السؤال هي:

1- الـ **=** (Lexeme) والموجودة في السطر الخامس، حيث يظهر Lexical analyzer رسالة خطأ للمبرمج يخبره

فيها بان الـ **(Lexeme)** = غير معروفة لديه ولا تنتمي الى اي قاعدة مایکروية والموجودة في السطر الخامس وانه لا يستطيع تنفيذ البرنامج مالم يتم تعديلها وربما يقترح عليه تعديلها الى = ومن ثم يقوم المبرمج بتعديلها الى = ليستمر تنفيذ البرنامج.

2- الـ **8i** (Lexeme) والموجودة في السطر الثامن ويقوم المستخدم بتعديلها الى 8 (نفس الاجراء المتبع كما في الخطورة رقم واحد).

3- الـ **@x** (Lexeme) والموجودة في السطر الثامن ويقوم المستخدم بتعديلها الى @ (نفس الاجراء المتبع كما في الخطورة رقم واحد).

4- الـ **<<** (Lexeme) والموجودة في السطر التاسع ويقوم المستخدم بتعديلها الى << (نفس الاجراء المتبع كما في الخطورة رقم واحد).

5- أما الفراغات الموجودة في السطر الخامس والفراغات الموجودة في البرنامج ككل فهي لا تظهر كأخطاء للمستخدم ولكن البرنامج يقوم بدمجها بفراغ واحد - أي يعتبرها فراغ واحد - بين كل Two Lexemes متتاليين (يعود مرة أخرى بخزن البرنامج المصدري كبرنامج جديد بين كل Lexeme ولـ Lexeme فراغ واحد فقط).

6- أما بقية الأخطاء الموجودة فعلًا في البرنامج فإن لـ Lexical analyzer لا يعتبرها أخطاء في هذا المرحلة.

(21)

### Solution (3): Lexemes after correction?

Sq.	Lexemes
1.	int
2.	main
3.	(
4.	)
5.	{
6.	int
7.	x
8.	,
9.	Ahmad
10.	,
11.	float
12.	y
13.	char
14.	Array
15.	[
16.	10
17.	,
18.	10
19.	]
20.	;
21.	x_y
22.	=
23.	5
24.	;
25.	switch
26.	(
27.	ch
28.	)
29.	case
30.	0
31.	:
32.	for

Sq.	Lexemes
33.	(
34.	int
35.	i
36.	=
37.	0
38.	;
39.	i
40.	<=
41.	9
42.	;
43.	I
44.	++
45.	Array
46.	[
47.	i
48.	]
49.	=
50.	8
51.	+
52.	yx
53.	*
54.	*
55.	x
56.	;
57.	Cout
58.	<<
59.	"ahmad"
60.	;
61.	print
62.	<
63.	<
64.	Ahmed
65.	}

في هذا المثال سوف يتم اعتبار ++ كـ(One lexeme). في هذا المثال سوف يتم اعتبار هذه الحالة. أما إذا قام المستخدم منفذ البداية في البرنامج المصدرى بفصلها بفراغ سوف يتم اعتبارها (Two lexemes).

هنا المستخدم قام بالتعديل عليها من << إلى << كـ(One lexeme). في المثال سوف نأخذ هذا الجانب. أما إذا قام بالتعديل عليها من << إلى < < بينهم فراغ كـ(Two lexemes) أيضا تعتبر صحيحة في هذه المرحلة.

(22)

### Solution (4 & 5): Token table and Symbol Table.

Table of Token		
Sq.	Token-name	Token-value
1.	int	K.W
2.	main	K.W
3.	(	Pun
4.	)	Pun
5.	{	Pun
6.	int	K.W
7.	x	Id 1
8.	,	Pun
9.	Ahmad	Id 2
10.	,	Pun
11.	float	K.W
12.	y	Id 3
13.	char	K.W
14.	Array	Id 4
15.	[	Pun
16.	10	Num
17.	,	Pun
18.	10	Num
19.	]	Pun
20.	;	Pun
21.	x y	Id 5
22.	=	Op
23.	5	Num
24.	;	Pun
25.	switch	K.W
26.	(	Pun
27.	ch	Id 6
28.	)	Pun
29.	case	K.W
30.	0	Num
31.	:	Pun
32.	for	K.W

Symbol Table		
Sq.	Token-name	
1.	x	
2.	Ahmad	
3.	y	
4.	Array	
5.	x_y	
6.	ch	
7.	i	
8.	I	
9.	yx	
10.	Cout	
11.	print	
12.	Ahmed	

Table of Token		
Sq.	Token-name	Token-value
33.	(	Pun
34.	int	K.W
35.	i	Id 7
36.	=	Op
37.	0	Num
38.	;	Pun
39.	i	Id 7
40.	<=	Op
41.	9	Num
42.	;	Pun
43.	I	Id 8
44.	++	Op
45.	Array	Id 2
46.	[	Pun
47.	i	Id 7
48.	]	Pun
49.	=	Op
50.	i	Id 7
51.	+	Op
52.	yx	Id 9
53.	*	Op
54.	*	Op
55.	x	Id 1
56.	;	Pun
57.	Cout	Id 10
58.	<<	Op
59.	"ahmad"	Literal
60.	;	Pun
61.	print	Id 11
62.	<	Op
63.	<	Op
64.	Ahmed	Id 12
65.	}	Pun

(23)

## Solution (6): Tokens stream.

```
<int,k.w> <main,k.w> <(,pun> <),pun> <{,pun> <int,k.w> <Id,1>
<,pun> <Id,2> <,pun> <float,k.w> <Id,3> <char,k.w> <Id,4> <[,pun>
<10,number> <,pun> <10,number> <],pun> <;,pun> <Id,5> <=,op>
<5,number> <;,pun> <switch,k.w> <(,pun> <Id,6> <),pun> <case,k.w>
<0,number> <:,pun> <for,k.w> <(,pun> <int,k.w> <Id,6> <=,op>
<0,number> <;,pun> <Id,6> <<=,GE> <9,number> <;,pun> <Id,8>
<++,op> <Id,4> <[,pun> <Id,7> <],pun> <=,op> <Id,7> <+,op> <Id,9>
<*,op> <*,op> <Id,1> <;,pun> <Id,10> <<<,pun> < "ahmad" , Literal >
<;,pun> <Id,11> <<,pun> <<,pun> <Id,12 > <},pun>
```

H.W.

(24)

Suppose that we have the following source program by C++. How to analyze it by the lexical analyzer to pass on to the syntax analyzer? After correct the errors in the lexical analyzer.

1	#include <iostream.h>
2	int main()
3	{
4	int xy , Ahmad ,
5	char Array [ 10 ] ; // Array is string
6	xy = 5 ;
7	x.1 = 7 ;
8	fot( int i=0 ; i<=9 ; I++ )
9	Array [ i ] = i + yx * * x 1 ;
10	Ahmad = x ,
11	Cout << Ahmad ;
12	}

**THANK YOU**