

COMSM1302 電腦架構概論

第八週完整教材：編譯器概念

詞法分析 · 符號表 · 語法分析與 BNF · Hack 組譯器

依據 John Lapinskas (University of Bristol) 課程講義編寫並延伸

2026 年 7 月

本教材的使用方式：本講義整合了第八週四份投影片 (8-1 Compiler concepts: Lexing、8-2 Compiler concepts: Symbol tables、8-3 Compiler concepts: Parsing、8-4 A parser for Hack assembly) 的全部內容，並補充了遞迴下降解析 (recursive descent) 等延伸知識。每章結尾附有「本章重點」整理；第 5 章為綜合練習題，附完整詳解。上週我們蓋完了 Hack 的硬體；本週正式跨入軟體：組譯器 (assembler) 是怎麼把組語文字變成機器碼的？這也是本週作業——用 C 寫一個自己的 Hack 組譯器——的理論基礎。

目錄

1	編譯器的全貌與詞法分析 (Lexing)	3
1.1	下一個目標	3
1.2	編譯器的分階段全貌	3
1.2.1	中介表示法 (IR)	3
1.2.2	語法 vs 語意	4
1.2.3	組譯器的簡化	4
1.3	The Joy of Lex: 權杖	4
1.4	Hack 組語的權杖	4
1.5	詞法分析的好處與範例輸出	5
2	符號表 (Symbol Tables)	7
2.1	問題：標籤與變數	7
2.2	識別字與符號表	8
2.3	符號表如何運作?	8
2.4	如何填符號表?	8

2.5 進階符號表：作用域 (Scopes)	9
3 語法分析與文法 (Parsing and Grammars)	11
3.1 描述語言：需要更好的工具	11
3.2 BNF 入門	11
3.3 遞迴：BNF 力量的來源	11
3.4 練習：更好的整數	12
3.5 解析樹 (Parse Trees / CST)	12
3.6 抽象語法樹 (AST)	13
3.7 歧義 (Ambiguity)	13
3.8 實務上怎麼做？用解析器產生器	13
3.9 擴充 BNF (EBNF)	13
4 Hack 組語的解析器	15
4.1 Hack 組語的 EBNF	15
4.2 兩棵範例 CST	15
4.3 LL 解析：由左往右、由上往下	16
4.4 實際上怎麼解析 Hack?	17
4.5 Hack 組譯器總結	17
5 綜合練習題 (附詳解)	19
A 附錄：速查表	24
A.1 Hack 權杖分類	24
A.2 組譯器流程圖	24
A.3 EBNF 記號速查	24
A.4 名詞中英對照	24
A.5 參考資料	25

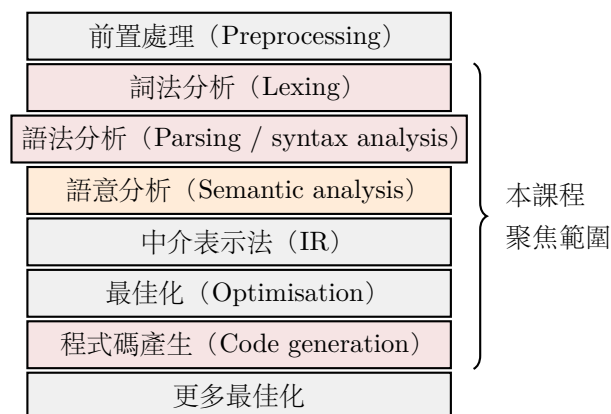
1 編譯器的全貌與詞法分析 (Lexing)

1.1 下一個目標

我們已經懂了 Hack 組語與 Hack ISA，也會用組譯器把組語變成機器碼。但組譯器本身是怎麼運作的？本週的目標：用 C 打造一個自己的 Hack 組譯器！在抽象階梯上，我們正在處理「組合語言 → ISA」這一步的翻譯軟體——而它的原理與「高階語言 → 組語」的編譯器一脈相承。

1.2 編譯器的分階段全貌

現代編譯器通常以離散的階段 (phases) 工作：



- **前置處理**：語言特定的步驟，例如把程式檔連結起來、執行編譯器巨集。在 C 中包括讀 makefile、處理 `#include` 與 `#define`。
- **最佳化**：自動把低效程式碼變成高效程式碼的過程。

兩者都超出本課程範圍。

1.2.1 中介表示法 (IR)

多數編譯器把語意分析萃取出的資訊放進程式碼的 **中介表示法 (intermediate representation, IR)**，然後對 IR (而非原始碼) 做最佳化。IR 是給電腦 (而非人類) 用的，相當接近組語；「最佳化 IR」是最佳化裡困難的那一半。許多語言可以編譯到同一個 IR——例如 LLVM 被用於 C#、Java bytecode、Ruby 與 Rust 的編譯器。下週起我們會看到 Hack 的 IR；但一行組語本來就對應一行機器碼，所以組譯器不需要 IR。

1.2.2 語法 vs 語意

語法 (syntax)

語言或程式碼的**邏輯結構**。以英文句子“The trophy wouldn’t fit in the case because it was too big.”為例，語法分析告訴你“trophy”和“case”是名詞、句子拆成兩個子句——關於文法結構的一切。以 `strcpy(x, "Test");` 為例，語法分析告訴你：這是對名為 `strcpy` 的函式的呼叫，第一個引數是變數 `x`、第二個是字串 `"Test"`。語法分析可以很複雜，但是**被透徹理解的問題**，有許多標準演算法。語法分析的過程稱為**解析 (parsing)**。

語意 (semantics)

語言或程式碼的**意義**。同一個英文句子，語意分析告訴你“it”指的是獎盃、不是櫃子——兩種解讀在文法上都合法，但只有一種說得通。對 `strcpy(x, "Test");`，語意分析會發現 `strcpy` 未定義（忘了 `#include <string.h>`）、`x` 是 `char *`，甚至找出「系統時間恰為午夜時指標指向未配置記憶體」的 bug。**語意分析非常困難**！型別檢查等部分已被充分理解，但自動抓 bug（「驗證」）仍是研究領域。

1.2.3 組譯器的簡化

對組譯器而言，語法與語意幾乎相同，常見做法是把語意分析**併入**詞法分析與解析。沒有複雜語意，也就不必把程式碼產生跟解析分開——逐行處理即可。

我們的 Hack 組譯器

只有兩個步驟：**詞法分析 (lexing)** 與**解析 (parsing)**。就 Hack 組語而言這其實還是殺雞用牛刀——但我們會完整地做，以建立通用的原理。

1.3 The Joy of Lex: 權杖

權杖 (token)

又稱 **lexeme** 或**詞法元素**：程式碼中「不可分割」的片段——再拆下去就會失去意義。英文裡最接近的類比是**單字與標點**：

Never | gonna | give | you | up | , | never | gonna | let | you | down | .

詞法分析 (lexing)

把一串程式碼**文字**轉換成一串**權杖**的過程。通常只需要移除空白並比對字串。

可用的權杖列表寫在程式語言的**規格書**裡，連同把權杖組成語句的**文法**（見第 3 章）。什麼算一個權杖是語言設計者的選擇，不是普世標準——例如 Java 把註解與空白當權杖，C 則不是。

1.4 Hack 組語的權杖

Nisan 與 Schocken 沒有給 Hack 組語文法，但我們可以自建。我們取以下權杖：

類別	內容
關鍵字 (keywords)	A、D、M; JGT、JEQ、JLT、JGE、JNE、JLE、JMP; SCREEN、KBD、SP、LCL、ARG、THIS、THAT; R0 到 R15
符號 (symbols)	@、+、-、&、 、=、;、!
整數字面值	任何 0...32767 範圍內的十進位整數
識別字 (identifiers)	任何不含空白、不是關鍵字、以字母開頭的字串
換行 (newlines)	

幾個關鍵觀察：

- A 與 ARG 是不同的關鍵字——區分它們要小心（不能看到 A 就停）。一般而言，**關鍵字**是語言本身賦予特殊意義、通常不能重新定義的字串。C 的關鍵字包括 `const`、`int`、`for`、`return`，但不包括 `printf`。
- C 把符號稱為 `punctuators` 與 `operators`，且有多字元符號如 `>=`、`==`、`%:` 與 `%: %:`（後兩者由於歷史因素是 `#` 與 `##` 的同義詞）。
- C 把字面值稱為 `constants`，還有字串、浮點、`enum` 與字元常數。
- 識別字代表在程式碼（而非語言）中定義的實體，例如特定變數、函式或 `struct` 型別。在 C 中 `printf` 是 `stdio` 函式庫定義的識別字。注意我們不區分變數與標籤——都先當識別字。
- C 完全忽略換行，但我們需要換行權杖——否則無法區分「A 之後接 `D=M`」與 `AD=M`。

注意少了什麼！空白與註解直接丟掉，不產生權杖。標籤也會被丟掉而不變成權杖（見第 2 章）——所以符號表裡不包括（和）。

1.5 詞法分析的好處與範例輸出

為什麼要費工夫做詞法分析？因為之後可以把權杖存成乾淨的 **struct**，從此不必再跟 C 糟糕的字串處理搏鬥（至少撐到程式碼產生階段…）。

詞法器輸出範例

考慮測試案例中的這行 Hack 程式碼：

```
D;JGT      // if D>0 goto output_first
```

你的詞法器會把它轉成四個 Token struct：

	type	value
Token 1	Keyword	D
Token 2	Symbol	;
Token 3	Keyword	JGT
Token 4	Newline	None

其中 D 與 JGT 以 `enum` 儲存、; 以 `char` 儲存；接著呼叫 `write_token` 把權杖寫入暫存檔。你的解析器再用 `read_token` 讀取 Token struct ——處理的是權杖檔，而不是原始碼。註解 `// if`

D>0 ... 被整個丟棄，不產生任何權杖。你的詞法器也會處理**標籤**（通常屬於語意分析）——見下一章！

本章重點

- 編譯器分階段：前置處理 → 詞法 → 語法 → 語意 → IR → 最佳化 → 產碼。組譯器只需**詞法+解析**兩步。
- 語法 = 結構（被透徹理解）；語意 = 意義（很難，驗證是研究領域）。
- 權杖 = 不可分割的程式碼片段；詞法分析 = 文字 → 權杖串。
- Hack 權杖五類：關鍵字／符號／整數字面值／識別字／換行；空白、註解、標籤宣告不產生權杖。
- 換行必須是權杖：否則 $A+D=M$ 與 $AD=M$ 無法區分。

2 符號表 (Symbol Tables)

2.1 問題：標籤與變數

回想 Hack 組語中 @ 後面可以接數字、標籤或變數。組譯器必須：

1. 為每個變數配置一個 RAM 位址（從 16 開始）；
2. 用位址取代變數；
3. 為每個標籤指定 ROM 位址——等於其宣告處對應的機器碼行號；
4. 用位址取代標籤；
5. 然後才把 @ 語句轉成 A-指令。

以投影片的範例程式追蹤整個過程（左：原始碼，右：完成後）：

行	原始碼	⇒	行	翻譯後
0	@input1	⇒	0	@16
1	D=M	⇒	1	D=M
2	@input2	⇒	2	@17
3	D=D-M	⇒	3	D=D-M
4	@output_first	⇒	4	@10
5	D;JGT	⇒	5	D;JGT
6	@input2	⇒	6	@17
7	D=M	⇒	7	D=M
8	@output_d	⇒	8	@12
9	0;JMP	⇒	9	0;JMP
10	(output_first)	⇒	10	@16
11	@input1	⇒	11	D=M
12	D=M	⇒	12	@18
13	(output_d)	⇒	13	M=D
14	@output_val	⇒	14	@14
15	M=D	⇒	15	0;JMP
16	(infinite_loop)	⇒		
17	@infinite_loop	⇒		
18	0;JMP	⇒		

關鍵陷阱：標籤宣告不佔機器碼行！（output_first）這種行會被整行移除，所以它後面的指令行號要往前縮。例如（output_first）原本在第 10 行，移除後「下一條指令」@input1 才是機器碼第 10 行——所以 output_first 的 ROM 位址是 10。同理 output_d → 12、infinite_loop → 14（三個標籤宣告依次被移除，行號累計前縮）。

我們用符號表完成這件事。

2.2 識別字與符號表

識別字 (identifier)

意義在程式碼本身（而非語言）中定義的權杖的統稱。在 Hack 中，識別字就是**標籤與變數**——看到 `@output_first` 時我們知道 `@` 是什麼意思，但 `output_first` 只能找它的定義才能翻譯。在 C 中，函式名稱也是識別字。

符號表 (symbol table)

把識別字的**名字**對應到其**意義**的資料結構。在 Hack 中我們用**兩張**符號表：標籤表（標籤名 → ROM 位址）與變數表（變數名 → RAM 位址）。在 C 中，符號表還會存變數的**型別**、函式的**引數**等——歷史上「**高效填符號表**」的需求正是**函式標頭 (headers)** 存在的原因。

上面範例對應的兩張表：

標籤表		變數表	
名稱	ROM 位址	名稱	RAM 位址
<code>output_first</code>	10	<code>input1</code>	16
<code>output_d</code>	12	<code>input2</code>	17
<code>infinite_loop</code>	14	<code>output_val</code>	18

2.3 符號表如何運作？

符號表必須支援三種操作：

1. 加入新的名稱與位址；
2. 檢查某名稱是否在表中；
3. 若在表中，取出對應的位址。

「正確」的實作方式是**雜湊表 (hash table)**（幾週後的 Programming in C 會教）。但用你已學過的**動態大小容器**（動態陣列）也能做，只是較沒效率——每次查詢線性掃描整個陣列即可。這是好的 C 練習、但不是好的架構練習，所以作業已幫你寫好——見 `symboltable.c` 與 `symboltable.h`。

2.4 如何填符號表？

在組語中，填符號表簡單到可以**整合進詞法分析與解析**（在 C 之類的語言中則發生在較後面的語意分析階段）。兩張表都從空表開始。

填表流程

詞法分析階段（處理標籤）：識別字是變數還是標籤，看有沒有**標籤宣告 (label)** 即可。於是在 `lexing` 時，我們**移除**標籤宣告、把它們與正確的 ROM 位址加進**標籤表**。（回想：標籤宣告**不產生任何權杖**！）

解析階段（處理變數）：對遇到的每個識別字，查兩張表：

- 在**標籤表**裡 → 太好了，代入 ROM 位址；
- 在**變數表**裡 → 太好了，代入 RAM 位址；
- 兩張表都沒有 → 必是某變數的**首次出現**：把它加進變數表，配置第一個未使用的 RAM 位址（從 16 起）。


為什麼標籤要在**詞法階段**先處理？因為變數與標籤在使用處長得一模一樣（都是 @ 名字），唯一能區分它們的是**宣告**；而 @ 名字可能出現在（名字）宣告之前（向前跳轉）。先掃一遍把所有標籤收齊，解析時才不會把標籤誤當新變數。

2.5 進階符號表：作用域 (Scopes)

高階語言的編譯器需要追蹤**作用域**：每個作用域建一張符號表。語意分析建好表後，轉換成 IR 時可以把它們存在一個**堆疊 (stack)** 裡。考慮這段 C 程式：

```

1  #include <stdio.h>
2
3  int main() {
4      double foo = 7;
5      char i = 'a';
6      for (int i = 0; i <= 5; i++) {
7          printf("%f, %d", foo, i);
8          foo /= 2;
9      }
10
11     foo = 50;
12     for (long i = 0; i <= 10; i++) {
13         double temp = foo + 500;
14         printf("%f, %d", temp, i);
15         foo *= 2;
16     }
17
18     printf("%c", i);    // Prints 'a'
19     printf("%d", temp); // Compile error!
20     return 0;
21 }
```



編譯器的堆疊操作：從表 1 開始，第 3 行 **push** 表 2、第 6 行 **push** 表 3、第 9 行 **pop** (for 迴圈結束)、第 12 行 **push** 表 4、第 16 行 **pop**、第 21 行 **pop**。查詢變數時從堆疊頂往下找，回傳第

一筆結果——這就是「內層變數遮蔽 (shadow) 外層同名變數」的機制：在第一個 for 內查 `i` 會先找到表 3 的 `int i`，而不是表 2 的 `char i`。第 18 行印出 'a' (表 3、表 4 已被 pop，查到表 2 的 `char i`)；第 19 行編譯錯誤 (`temp` 只存在於已被 pop 的表 4)。

本章重點

- 組譯器的任務順序：配置變數 RAM 位址 (16 起) → 標籤取 ROM 位址 (宣告處的機器碼行號) → 全部替換 → 才轉 A-指令。
- 標籤宣告行被移除、不佔機器碼行號——後續行號要前縮。
- 符號表 = 名稱 → 意義的映射；支援加入／檢查／取出；正解是雜湊表，動態陣列也可。
- 標籤在詞法階段填表 (因為要靠宣告區分、且可能向前跳轉)；變數在解析階段「查無此人則新增」。
- 高階語言：一個作用域一張表、用堆疊管理，由頂往下查——內層遮蔽外層。

3 語法分析與文法 (Parsing and Grammars)

3.1 描述語言：需要更好的工具

Nisan 與 Schocken 對 Hack 語法的描述散落在說明文字裡——對人讀還行，對寫解析器來說不夠精確方便。我們需要一個高度精密的數學工具：**Madlibs**（填詞遊戲）！

上下文無關文法 (context-free grammar)

一種快速且嚴謹地指定「語言中哪些字串具有合法語法」的方式。背後有深厚的數學理論（好在不用學）。程式設計師用 **Backus-Naur Form (BNF)** 表達文法，而且通常看懂 BNF 就夠用了。BNF 基本上就是會遞迴的 Madlibs。

3.2 BNF 入門

一個簡單例子：

$$\begin{aligned}\langle noun \rangle &::= \text{'lecturer'} \mid \text{'student'} \mid \text{'pizza'} \\ \langle presentVerb \rangle &::= \text{'eats'} \mid \text{'devours'} \mid \text{'consumes'}\end{aligned}$$

每個 $\mid$ 讀作「或」、每個 $::=$ 讀作「定義為」。例如一個 $\langle noun \rangle$ 定義為 'lecturer'、'student'、'pizza' 三個字串之一。定義可以疊起來：

$$\langle sentence \rangle ::= \text{'The'} \langle noun \rangle \langle presentVerb \rangle \text{'the'} \langle noun \rangle$$

合法的 $\langle sentence \rangle$ 包括「The lecturer consumes the pizza」、「The student eats the pizza」、「The lecturer devours the student」。

終端與非終端符號

文法中我們自己定義的東西必須包在 $\langle \rangle$ 裡，稱為非終端符號 (non-terminal symbols)。其他的（如 'lecturer'）是終端符號 (terminal symbols) ——也就是權杖。

3.3 遞迴：BNF 力量的來源

BNF 的最後一個特性是力量的來源：允許遞迴。假設權杖是 '0' 到 '9'，想定義一個非終端符號恰好匹配所有非負整數（允許前導零）：

$$\begin{aligned}\langle digit \rangle &::= \text{'0'} \mid \text{'1'} \mid \text{'2'} \mid \text{'3'} \mid \text{'4'} \mid \text{'5'} \mid \text{'6'} \mid \text{'7'} \mid \text{'8'} \mid \text{'9'} \\ \langle number \rangle &::= \langle digit \rangle \mid \langle digit \rangle \langle number \rangle\end{aligned}$$

例如 016 是 $\langle number \rangle$ ，因為可以這樣展開：

$$\langle number \rangle \rightarrow \langle digit \rangle \langle number \rangle \rightarrow \langle digit \rangle \langle digit \rangle \langle number \rangle \rightarrow \langle digit \rangle \langle digit \rangle \langle digit \rangle \rightarrow \text{'0'} \text{'1'} \text{'6'}.$$

就這樣！這就是全部的 BNF。用起來與推理起來可能很難，但語法本身很簡單。

3.4 練習：更好的整數

如何重新定義 $\langle number \rangle$ ，允許負數但禁止前導零？（權杖有 '0' 到 '9' 和 '-'。）任何重定義的健全性檢查：

- $\text{'-'}\text{'1'}\text{'0'}$ 應該是 $\langle number \rangle$ ；✓
- '0' 應該是 $\langle number \rangle$ ；✓
- $\text{'0'}\text{'1'}$ 不應該是 $\langle number \rangle$ ；✗
- $\text{'-'}\text{'0'}$ 不應該是 $\langle number \rangle$ 。✗

做法很多——BNF 的文法表達沒有唯一「正確」寫法。其中一種：

$$\begin{aligned}\langle posDigit \rangle &::= \text{'1'} \mid \text{'2'} \mid \text{'3'} \mid \text{'4'} \mid \text{'5'} \mid \text{'6'} \mid \text{'7'} \mid \text{'8'} \mid \text{'9'} \\ \langle posNumber \rangle &::= \langle posDigit \rangle \mid \langle posNumber \rangle \langle posDigit \rangle \mid \langle posNumber \rangle \text{'0'} \\ \langle number \rangle &::= \langle posNumber \rangle \mid \text{'-'} \langle posNumber \rangle\end{aligned}$$


思路： $\langle posNumber \rangle$ 的第一個字元只能經由 $\langle posDigit \rangle$ 產生（非零），之後可以接任何數字（包括 0）； '0' 只允許單獨出現，且負號後面只能接 $\langle posNumber \rangle$ 。

3.5 解析樹 (Parse Trees / CST)

解析的目標

把權杖列表轉換成解析樹 (parse tree)，又稱具體語法樹 (concrete syntax tree, CST)，呈現它的 BNF 結構。每個非終端符號是一個節點，其子節點是它的 BNF 展開（由左至右）——所以葉子恰好是權杖。


以“-886”為例（用上面的文法）：



展開路徑： $\langle number \rangle \rightarrow \text{'-'} \langle posNumber \rangle$ ； $\langle posNumber \rangle \rightarrow \langle posNumber \rangle \langle posDigit \rangle$ （吃掉 6） $\rightarrow \langle posNumber \rangle \langle posDigit \rangle$ （吃掉第二個 8） $\rightarrow \langle posDigit \rangle$ （吃掉第一個 8）。

3.6 抽象語法樹 (AST)

為了效率與方便，我們可以把 CST 加工成 **抽象語法樹 (abstract syntax tree, AST)**：相同的資訊、更方便的形式。例如決定不需要 $\langle posDigit \rangle$ 節點，把數字直接標在節點上：



3.7 歧義 (Ambiguity)

考慮這個簡單算術運算式的文法：

$$\begin{aligned}
 \langle expression \rangle &::= \langle number \rangle \mid \langle expression \rangle \langle operator \rangle \langle expression \rangle \\
 &\quad \mid '(\langle expression \rangle \langle operator \rangle \langle expression \rangle) ' \\
 \langle operator \rangle &::= '+' \mid '-' \mid '*' \mid '/' \mid '^'
 \end{aligned}$$

那麼對 $(3 + 4) * (5 - 1) / 3$ ，解析器可以輸出好幾棵不同的合法 CST（先把 * 當根、還是先把 / 當根？）。只要語意不歧義（此處無論哪棵樹算出來都一樣），這種歧義是可以接受的。但在真實語言中（如 $3 - 4 - 5$ 的左右結合、或懸掛 else），文法設計者通常會改寫文法來消除歧義。

3.8 實務上怎麼做？用解析器產生器

解析是困難而微妙、但被透徹理解的問題——這代表我們不該自己重新解決它！應該用**解析器產生器 (parser generator)**：把 BNF 文法餵給它，它輸出你選定語言的解析器程式碼。（例如 C 的 yacc。）

3.9 擴充 BNF (EBNF)

解析器產生器與語言規格書常為易用性給 BNF 加語法，但沒有統一標準。鬆散依據 ISO 14977，我們加入：

記號	意義	例子
()	分組	$(\langle 0 \rangle \mid \langle 1 \rangle)$ 匹配 00、01、10、11
[]	可有可無	$[\langle 0 \rangle \mid \langle 1 \rangle]$ 匹配 01 或 1
{ }	重複任意次	$\{\langle 0 \rangle \mid \langle 1 \rangle\}$ 匹配任何 0/1 串（含空字串）
$A - B$	匹配 A 但不匹配 B	$\langle number \rangle - \langle digit \rangle$ ：不是單一數字的數

($A - B$ 只在 B 只能展開成**有限多**種權杖序列時是合法 EBNF，例如 $\langle number \rangle - \langle posNumber \rangle$ 就不合法。)

EBNF 沒有讓 BNF 能表達任何原本表達不了的文法（每個 EBNF 構造都能機械地改寫回純 BNF——分組展開、選項用兩條規則、重複用遞迴），但**讀寫舒服得多**。例如「更好的整數」變成一行：

$$\langle number \rangle ::= (['- '] (\langle digit \rangle - '0') \{ \langle digit \rangle \}) | '0'$$

有了 EBNF，連整個 C 語言的文法都能寫得可讀，何況 Hack！

本章重點

- BNF: $::=$ 定義、 $|$ 或、 $\langle \rangle$ 非終端、引號內為終端（權杖）；**遞迴**是力量來源。
- 同一語言的 BNF 寫法不唯一；用健全性檢查驗證你的文法。
- CST: 非終端 = 節點、BNF 展開 = 子節點、葉子 = 權杖。AST = 同資訊的方便形式。
- 歧義: 多棵合法 CST；語意一致時可接受。
- 實務用解析器產生器 (yacc 等)；EBNF 的 $()[]\{\}$ 與 $-$ 只是語法糖。

4 Hack 組語的解析器

4.1 Hack 組語的 EBNF

把 Hack 形式化成 EBNF 的方式很多，以下是其中一種（，表示串接、；結束一條規則——這是 ISO 風格 EBNF 的慣例）：

Hack 組語文法

```


<instruction> ::= (<aInstruction> | <cInstruction>), newline;
<aInstruction> ::= "@", (integerLiteral | identifier | <memoryKeyword>);
<memoryKeyword> ::= "SCREEN" | "KBD" | "SP" | "LCL" | "ARG" | "THIS" | "THAT";
<cInstruction> ::= [<assignment>], <computation>, [<jump>];
<assignment> ::= ("A" | "D" | "M" | ("A", "D") | ("A", "M") | ("D", "M")
                  | ("A", "D", "M")), "=";
<jump> ::= ";", ("JMP" | "JGT" | "JEQ" | "JLT" | "JGE" | "JNE" | "JLE");
<computation> ::= "0"
                  | ("[-", "1")
                  | ("[-" | "!", ("A" | "D" | "M"))
                  | (("A" | "D" | "M"), ("+" | "-"), "1")
                  | (("A" | "M"), <binaryOp>, "D")
                  | ("D", <binaryOp>, ("A" | "M"));
<binaryOp> ::= "+" | "-" | "&" | "|";

```


注意這個文法如何精準編碼第七週的 comp 表：<computation> 的六個分支恰好對應常數（0、±1）、單運算元（含 -、!）、加減一、以及 D 與 A/M 的二元運算——文法本身就排除了 A+M 這種不存在的運算。

4.2 兩棵範例 CST

例一：0;JMP\n



例二：DM=M+D;JLE\n



4.3 LL 解析：由左往右、由上往下

LL 解析

本課程只考慮 **LL 解析**：由左至右掃過權杖，只看接下來的幾個權杖，從上往下建構 CST。(LL = Left-to-right scan、Leftmost derivation。)

逐權杖追蹤例一 0;JMP\n:

1. 讀到 0: 0 只可能是一整個 *<computation>*，它必在 *<cInstruction>* 裡、又必在 *<instruction>* 裡——三個節點一次掛好。也得知這個 *<cInstruction>* 沒有 *<assignment>*（但可能有 *<jump>*）。
2. 讀到 ;: 只可能是 *<jump>* 的第一項，掛進已有的 *<cInstruction>*。
3. 讀到 JMP: 必是那個 *<jump>* 的延續。
4. 讀到 \n: 必是 *<instruction>* 的結尾。完成！

若某一步下一個權杖無處可掛（例如解析 01;JMP 中的 1 時），就回報錯誤。

逐權杖追蹤例二 DM=M+D;JLE\n——需要往前看：

1. 讀到 D: 無法立刻判斷它屬於 *<assignment>* 還是 *<computation>*！解法：往前看 (lookahead) 第二個權杖——若是 M 或 =, 必在 *<assignment>*；若是 +、-、&、|、; 或 \n, 必在 *<computation>*。這裡下一個是 M，所以 D 開啟一個 *<assignment>*。
2. 讀到 M: 往前看見 =, 確認仍在 *<assignment>*。
3. 讀到 =: 只能收尾這個 *<assignment>*。
4. 讀到 M: 往前看見 +, 必在 *<computation>*。
5. 讀到 +: 可能是 M+1 型也可能是 M+D 型——再往前看一個權杖分辨；這裡是 *<binaryOp>*，並預期 *<computation>* 的下一項是 D。
6. 讀到 D、;、JLE、\n: 依次完成 *<computation>*、*<jump>* 與整個 *<instruction>*。

LL(k)

能靠往前看 k 個權杖完成 LL 解析的文法稱為 **LL(k)**。Hack 是 **LL(2)**（因為 $DM=M+D$ 這類情況）但不是 LL(1)。

警告 (原話): 這裡掃了很多很深的兔子洞到地毯下。不是所有文法都是 LL(k), 這也不是 LL(k) 的正式定義。但對一個 quick and dirty 的解析器實作來說夠用了! **延伸補充:** 手寫 LL 解析器的標準做法叫 **遞迴下降 (recursive descent)**: 每條文法規則寫成一個函式, 函式之間依文法結構互相呼叫; 需要注意**左遞迴**的規則 (如 $\langle posNumber \rangle ::= \langle posNumber \rangle \langle posDigit \rangle$) 會讓樸素的遞迴下降無窮遞迴, 須改寫成迴圈或右遞迴。GCC 與 Clang 的 C/C++ 解析器都是手寫的遞迴下降。

4.4 實際上怎麼解析 Hack?

CST 對優雅的錯誤處理和編譯 $i=(k+j++)/m$ 這種複雜運算式極有用, 但對 Hack 來說是殺雞用牛刀。我們實際需要知道的只有:

- 這條語句是 A-指令還是 C-指令? (第一個權杖是不是 @?)
- 若是 A-指令, 該載入 A 的值是多少? (@ 後面是什麼? 若是識別字, 查符號表拿 RAM/ROM 位址。)
- 若是 C-指令, dest、comp、jump 的值是多少?
 - = 有沒有出現? 左邊有 A、D、M 中的哪些?
 - ; 有沒有出現? 右邊是哪個跳躍指令?
 - = 右邊、; 左邊是什麼? (約 30 種可能。)

這些問題全都能用對權杖的簡單邏輯回答。(不過如果有多多的時間, 把 CST 做出來仍是很好的練習!)

4.5 Hack 組譯器總結

完整的兩趟式 (two-pass) 組譯器

第一趟: 詞法分析。對每一行:

- 移除所有註解與空白;
- 空行直接跳過;
- 若該行是**標籤宣告**, 把它與目前行對應的 **ROM 位址**加入符號表 (該行本身不輸出);
- 否則把該行拆成權杖、輸出到暫存檔。

第二趟: 解析。對每個 $\langle instruction \rangle$ (以換行權杖分隔):

- 若以 @ 權杖開頭:

- 用到**新變數** → 配置 RAM、加入符號表；
 - 用到**既有變數或標籤** → 從符號表取回 RAM/ROM 位址；
 - 產生並輸出對應的 **A-指令**。
- 否則：拆解成 assignment、computation、condition 三部分，分別映射到 dest、comp、jump 的位元值，產生並輸出對應的 **C-指令**。

注意這把第七週（機器碼格式）與本週（詞法+符號表+解析）完全接起來了：第二趟輸出的每一行，就是查第七週那三張表得到的 16 個位元。

本章重點

- Hack 的 EBNF: $\langle instruction \rangle = (\langle aInstruction \rangle \mid \langle cInstruction \rangle) + \text{newline}$; $\langle cInstruction \rangle = [\langle assignment \rangle] \langle computation \rangle [\langle jump \rangle]$ 。
- LL 解析：左到右、上到下、只看接下來幾個權杖；掛不進去就是語法錯誤。
- Hack 是 LL(2) 不是 LL(1)：看到 D 得再看一個權杖才知道是指定還是運算。
- 實務捷徑：不建 CST，用權杖邏輯直接回答「A 還是 C? dest / comp / jump 是什麼?」
- 兩趟式組譯器：第一趟收標籤、產權杖檔；第二趟配變數、查表、輸出機器碼。

5 綜合練習題（附詳解）

練習 1：詞法分析

把下列各行 Hack 程式碼轉成權杖序列（標明 type 與 value）：(a) @R13；(b) AM=M-1 // pop；(c) @counter。

解答

- (a) Token 1: (Keyword, R13)——注意 R13 是 **關鍵字**不是識別字！前面還有 Token 0: (Symbol, @)，最後 (Newline)。完整：**Symbol @、Keyword R13、Newline**。
- (b) **Symbol A?** 不對——AM 要拆成 **兩個關鍵字權杖**：Keyword A、Keyword M、Symbol =、Keyword M、Symbol -、整數字面值 1、Newline。註解 // pop 被丟棄，不產生權杖。
- (c) Symbol @、**識別字 counter**（不含空白、非關鍵字、字母開頭）、Newline。

練習 2：關鍵字 vs 識別字

判斷下列字串被詞法器歸為哪一類，並說明理由：(a) ARG；(b) ARGS；(c) R16；(d) 2fast；(e) loop。

解答

- (a) **關鍵字**——在關鍵字列表中。
- (b) **識別字**——不在列表中（雖然以 ARG 開頭）。詞法器必須**完整比對**，不能貪心地匹配前綴就停——這正是「A 與 ARG 是不同關鍵字，要小心區分」的意思。
- (c) **識別字**——關鍵字只有 R0 到 R15，R16 不在其中。
- (d) **都不是**——**詞法錯誤**。它不是整數字面值（含字母）、也不是識別字（不以字母開頭）。
- (e) **識別字**——Hack 組語沒有 loop 關鍵字（它多半是使用者定義的標籤或變數名）。

練習 3：為什麼需要換行權杖？

(a) C 完全忽略換行，為什麼我們的 Hack 詞法器不能？舉具體例子。(b) 為什麼（和）不是我們的符號權杖？

解答

- (a) 沒有換行權杖時，權杖序列 Keyword A、Keyword D、Symbol =、Keyword M 有兩種讀法：一行的 AD=M，或兩行的 A 與 D=M ——語意完全不同（前者是一條指令，後者第一行甚至不合法）。換行權杖讓指令邊界明確。C 不需要，因為 C 用；與大括號標記語句邊界。
- (b) 因為括號只出現在**標籤宣告**（label）中，而標籤宣告在**詞法階段就被整行移除**（加入標籤表、不輸出權杖）——解析器永遠不會看到括號，自然不需要它們的權杖。

練習 4：填符號表

對下列程式跑完整個組譯流程，寫出標籤表、變數表與最終輸出（以 @ 位址形式）：

```
@x
M=0
(loop)
@x
M=M+1
@y
D=M
@loop
D;JGT
```

解答

第一趟（詞法）：逐行給機器碼行號，遇到標籤宣告就記錄並移除：行 0 @x、行 1 M=0、(loop) → 標籤表 loop → 2（下一條指令的行號）、行 2 @x、行 3 M=M+1、行 4 @y、行 5 D=M、行 6 @loop、行 7 D;JGT。

第二趟（解析）：@x：兩表皆無 → 新變數，RAM 16。@x（第二次）：變數表命中 → 16。@y：兩表皆無 → 新變數，RAM 17。@loop：標籤表命中 → ROM 2。

標籤	ROM	變數	RAM
loop	2	x	16
		y	17

輸出：@16、M=0、@16、M=M+1、@17、D=M、@2、D;JGT（共 8 條機器碼指令）。

練習 5：標籤行號的陷阱

某程式有 20 行組語，其中第 5、10、15 行（從 0 數起）是標籤宣告 (a)、(b)、(c)。三個標籤的 ROM 位址各是多少？

解答

標籤宣告不佔機器碼行號，且前面每個被移除的標籤都會讓後續行號前縮一格。(a) 在原始第 5 行，前面沒有標籤被移除，其後第一條指令的機器碼行號是 $5 - 0 = 5$ 。(b) 在原始第 10 行，前面已移除 1 個標籤，ROM 位址 = $10 - 1 = 9$ 。(c) 在原始第 15 行，前面已移除 2 個標籤，ROM 位址 = $15 - 2 = 13$ 。（實作上不用做這種減法：第一趟維護一個「目前機器碼行號」計數器，只在輸出指令行時遞增、標籤行不遞增即可。）

練習 6：BNF 判定

用「更好的整數」文法 ($\langle posDigit \rangle$ / $\langle posNumber \rangle$ / $\langle number \rangle$) 判定下列字串是否為合法 $\langle number \rangle$ ，合法者寫出展開過程：(a) -305；(b) 007；(c) 0；(d) --5。

解答

- (a) 合法: $\langle number \rangle \rightarrow '-' \langle posNumber \rangle \rightarrow '-' \langle posNumber \rangle \langle posDigit \rangle \rightarrow '-' \langle posNumber \rangle '0' \langle posDigit \rangle \dots$ 等等 —— 小心! 305 的展開: $\langle posNumber \rangle \rightarrow \langle posNumber \rangle \langle posDigit \rangle$ (尾巴 '5') $\rightarrow (\langle posNumber \rangle '0') \langle posDigit \rangle$ (中間 '0') $\rightarrow (\langle posDigit \rangle '0') \langle posDigit \rangle \rightarrow '3' '0' '5'$ 。✓
- (b) 不合法: $\langle number \rangle$ 的三個分支中, 單獨 '0' 只匹配一個字元; $\langle posNumber \rangle$ 的第一個字元必來自 $\langle posDigit \rangle$ (1-9), 不能是 0。前導零被擋掉。✗
- (c) 合法: $\langle number \rangle \rightarrow '0'$ (第二分支)。✓
- (d) 不合法: '-' 只能出現一次 (第三分支 $-' \langle posNumber \rangle$), 且 $\langle posNumber \rangle$ 展不出 '-'。✗

練習 7: 自己寫 BNF

寫一個 BNF 文法, 權杖為 '0' 與 '1', 使 $\langle binary \rangle$ 恰好匹配無前導零的二進位正整數 (1、10、101 合法; 0、01 不合法)。再用 EBNF 重寫成一行。

解答

BNF (其中一種寫法):

$$\begin{aligned} \langle bit \rangle &::= '0' \mid '1' \\ \langle binary \rangle &::= '1' \mid \langle binary \rangle \langle bit \rangle \end{aligned}$$

第一個字元只能經由基底情形 '1' 產生, 之後每個 $\langle bit \rangle$ 都可以是 0 或 1。

EBNF 一行版:


$$\langle binary \rangle ::= '1', \{ '0' \mid '1' \}$$

健全性檢查: 1 ✓ (重複零次); 10、101 ✓; 0 ✗ (必須以 '1' 開頭); 01 ✗。

練習 8: 畫 CST

用第 4 章的 Hack 文法, 畫出 $D=D-1$ 的 CST。

解答



要點: 這條指令沒有 $\langle jump \rangle$ (可選項缺席); $D-1$ 走的是 $\langle computation \rangle$ 的第四分支 ($(\text{"A"}|\text{"D"}|\text{"M"}), (\text{"+"}|\text{"-"}), \text{"1"})$, 其中 - 是直接的終端符號、不經過 $\langle binaryOp \rangle$ (那是 $D-A$ 型分支用的)。

練習 9: EBNF $\rightarrow$ BNF

把下列 EBNF 規則改寫成純 BNF（可新增非終端符號）：

$$\langle list \rangle ::= "(, [\langle item \rangle, \{", \langle item \rangle\}, ")"$$

（一個括號包起來的、以逗號分隔的 item 列表，允許空列表。）

解答

$$\begin{aligned}\langle list \rangle &::= '(\text{'})' \mid '(\langle items \rangle \text{'})' \\ \langle items \rangle &::= \langle item \rangle \mid \langle item \rangle ', ' \langle items \rangle\end{aligned}$$

技巧總結：可選項 $[X]$ $\rightarrow$ 寫兩條規則（有 X 與沒 X ）；重複 $\{X\}$ $\rightarrow$ 新增遞迴非終端符號。這也示範了為什麼 EBNF 沒有增加表達能力——每個構造都能機械地展開回 BNF。

練習 10: LL(1) vs LL(2)

(a) 解釋為什麼解析器讀到 $DM=M+D$ 的第一個 D 時，只看這一個權杖無法決定 CST 的形狀。(b) 往前看一個權杖後，哪些「下一個權杖」意味著 $\langle assignment \rangle$ ？哪些意味著 $\langle computation \rangle$ ？(c) $0; \text{JMP}$ 需要 lookahead 嗎？為什麼？

解答

- (a) D 既可以開啟 $\langle assignment \rangle$ （如 $D=\dots, DM=\dots$ ），也可以自己就是 $\langle computation \rangle$ （如 $D; \text{JGT}$ 或單純 $D+1$ ）。兩種情況掛的節點不同，單看 D 無法分辨。
- (b) 下一個權杖是 M 或 $=$ $\rightarrow \langle assignment \rangle$ ；是 $+$ 、 $-$ 、 $\&$ 、 $|$ 、 $;$ 或 $\backslash n$ $\rightarrow \langle computation \rangle$ 。
- (c) 不需要。 0 在文法中只能是一整個 $\langle computation \rangle$ （ $\langle assignment \rangle$ 不可能以 0 開頭），所以第一個權杖就唯一決定了結構。需要兩個權杖的只有 $A / D / M$ 開頭的情況——這正是 Hack 是 LL(2) 而非 LL(1) 的原因。

練習 11: 作用域堆疊

用第 2 章的 C 程式回答：(a) 在第 7 行（第一個 for 內的 `printf`），查詢 `i` 得到什麼型別？查詢 `foo` 呢？(b) 為什麼第 18 行印出 `'a'`？(c) 為什麼第 19 行編譯錯誤？

解答

- (a) 此時堆疊（頂到底）：表 3、表 2、表 1。查 `i`：表 3 命中 $\rightarrow$ `int`（第一個 for 自己宣告的計數器，遮蔽外層的 `char i`）。查 `foo`：表 3 沒有 $\rightarrow$ 往下到表 2 命中 $\rightarrow$ `double`。
- (b) 第 18 行時表 3、表 4 都已被 pop，堆疊只剩表 2、表 1。查 `i` 命中表 2 的 `char i = 'a'`——迴圈裡對「它們自己的 `i`」做的所有遞增都發生在早已消失的內層變數上。
- (c) `temp` 只存在於表 4（第二個 for 的作用域），該表在第 16 行已被 pop。查遍剩下的表都找不到 `temp` $\rightarrow$ 未宣告識別字，編譯錯誤。

練習 12：端到端組譯

把下列程式完整組譯成 16 位元機器碼（用第七週的編碼表）：

```
@5
D=A
(wait)
@wait
0;JMP
```

解答

第一趟：行 0 @5、行 1 D=A、標籤 wait → ROM 2、行 2 @wait、行 3 0;JMP。

第二趟：

- @5：整數字面值，A-指令：opcode 0 + 5 的 15 位元二進位 → 00000000000000101。
- D=A：comp A ($a=0$, $c=110000$)、dest D= (010)、無 jump (000) → 111 0110000 010 000 = 1110110000010000。
- @wait：標籤表命中 → @2 → 0000000000000010。
- 0;JMP：comp 0 (0101010) 、dest 000、jump JMP (111) → 111 0101010 000 111 = 1110101010000111。


四條機器碼指令，變數表保持空（本程式沒有變數）。這就是你的組譯器對這個輸入應產生的**精確輸出**。

A 附錄：速查表

A.1 Hack 權杖分類

類別	成員	C 的對應
關鍵字	A D M; JGT JEQ JLT JGE JNE JLE JMP; SCREEN KBD SP LCL ARG THIS THAT; R0–R15	keywords (int、for…)
符號	@ + - & = ; !	punctuators / operators
整數字面值	十進位 0–32767	constants
識別字	無空白、非關鍵字、字母開頭	identifiers (printf…)
換行	\n	(C 忽略)
不產生權杖：空白、註解、標籤宣告 (label) (含括號本身)		

A.2 組譯器流程圖



A.3 EBNF 記號速查

記號	意義
::=	定義為
	或
⟨X⟩	非終端符號
‘x’ 或 “x”	終端符號 (權杖)
()	分組
[]	可選 (0 或 1 次)
{ }	重複 (0 次以上)
$A - B$	匹配 A 但排除 B (B 須有限)

A.4 名詞中英對照

英文	中文	英文	中文
lexing / lexer	詞法分析／詞法器	context-free grammar	上下文無關文法
token / lexeme	權杖／詞素	Backus-Naur Form (BNF)	BNF 範式
parsing / parser	解析／解析器	terminal symbol	終端符號
syntax / semantics	語法／語意	non-terminal symbol	非終端符號
keyword	關鍵字	parse tree / CST	解析樹／具體語法樹
identifier	識別字	abstract syntax tree	抽象語法樹
integer literal	整數字面值	ambiguity	歧義
symbol table	符號表	parser generator	解析器產生器
label / variable	標籤／變數	LL(k) parsing	LL(k) 解析
scope	作用域	lookahead	往前看
shadowing	遮蔽	recursive descent	遞迴下降
intermediate representation	中介表示法	two-pass assembler	兩趟式組譯器

A.5 參考資料

- John Lapinskas, *Compiler concepts: Lexing / Symbol tables / Parsing / A parser for Hack assembly* (8-1 至 8-4), COMSM1302, University of Bristol.
- Nisan & Schocken, *The Elements of Computing Systems* (nand2tetris), Ch. 6 (The Assembler) .
- Aho, Lam, Sethi & Ullman, *Compilers: Principles, Techniques, and Tools* (「龍書」——詞法、文法與解析的標準教科書) .
- ISO/IEC 14977, *Extended BNF* (EBNF 標準) .
- C11 標準 (ISO/IEC 9899:2011) §6.4 Lexical elements (C 的權杖定義) .
- Clang 原始碼 `clang/lib/Parse/` (工業級手寫遞迴下降解析器的實例) .