

# Context-Free Grammars

นำเสนอโดย

ดร.สุธี สดประเสริฐ

1

## บทนำ

- ❑ เราทราบกันแล้วว่า **finite automata regular, expressions** และ **regular grammar** ไม่สามารถจดจำภาษาบางอย่างได้  
เช่น  $\{0^n 1^n \mid n \geq 0\}$  หรือ  $\{a^n!\}$
- ❑ สำหรับภาษา  $L = \{0^n 1^n \mid n \geq 0\}$  หากเราเปลี่ยน 0 เป็น ( และ 1 เป็น )  
ดังนั้นสตริงในภาษานี้คือ () (()) หรือ (((())) แต่ว่าสตริง () จะไม่อยู่ใน  
ภาษานี้
- ❑ ภาษาดังกล่าวเป็นตัวอย่างของโครงสร้างแบบซ้อน (nested structure)  
อย่างง่าย
- ❑ ดังนั้นภาษา **regular** จึงมีความสามารถไม่เพียงพอในการอธิบายบางคุณสมบัติ  
ของภาษาโปรแกรม

2

## บทนำ

- ❑ **Context-free grammars (CFG)** เป็นแบบจำลองการ  
คำนวณหนึ่งที่มีความสามารถในการอธิบายภาษามากกว่าแบบจำลอง  
อื่นๆ ก่อนหน้านี้
- ❑ ไวยากรณ์แบบนี้มีลักษณะเด่นคือมีโครงสร้างแบบ **recursive  
structure**
- ❑ CFG ถูกเริ่มใช้ครั้งแรกในการอธิบายภาษามนุษย์ (ภาษาธรรมชาติ)

3

## บทนำ

- ❑ CFG มีบทบาทสำคัญในการเขียนข้อกำหนดและการคอมไพล์  
โปรแกรมภาษา (programming languages)
- ❑ การออกแบบและสร้างตัวแปลภาษา (compilers and  
interpreters) สำหรับโปรแกรมภาษาหนึ่ง มักจะเริ่มต้นจาก  
ไวยากรณ์ของภาษานั้น

4

# ไวยากรณ์บางส่วนของภาษา C

statement  $\rightarrow$  labeled\_statement | compound\_statement | expression\_statement | selection\_statement | iteration\_statement | jump\_statement

loop  $\rightarrow$  iteration\_statement

iteration\_statement  $\rightarrow$  while (expression) statement | do statement while (expression) ; | for\_statement

for\_statement  $\rightarrow$  for (expression ; expression ; expression) statement

selection\_statement  $\rightarrow$  if\_statement | switch (expression) statement

if\_statement  $\rightarrow$  if (expression) statement | if (expression) statement else statement

5

# ไวยากรณ์บางส่วนของภาษา Java (Java Syntax Specification)

## Programs

$\langle$  compilation unit  $\rangle ::= \langle$  package declaration  $\rangle? \langle$  import declarations  $\rangle? \langle$  type declarations  $\rangle?$

## Declarations

$\langle$  package declaration  $\rangle ::=$  package  $\langle$  package name  $\rangle$  ;  $\langle$  import declarations  $\rangle ::= \langle$  import declaration  $\rangle | \langle$  import declarations  $\rangle \langle$  import declaration  $\rangle$

$\langle$  import declaration  $\rangle ::= \langle$  single type import declaration  $\rangle | \langle$  type import on demand declaration  $\rangle$

$\langle$  single type import declaration  $\rangle ::=$  import  $\langle$  type name  $\rangle$  ;

$\langle$  type import on demand declaration  $\rangle ::=$  import  $\langle$  package name  $\rangle$  . \* ;

$\langle$  type declarations  $\rangle ::= \langle$  type declaration  $\rangle | \langle$  type declarations  $\rangle \langle$  type declaration  $\rangle$

$\langle$  type declaration  $\rangle ::= \langle$  class declaration  $\rangle | \langle$  interface declaration  $\rangle$  ;

$\langle$  class declaration  $\rangle ::= \langle$  class modifiers  $\rangle? \text{class} \langle$  identifier  $\rangle \langle$  super  $\rangle? \langle$  interfaces  $\rangle? \langle$  class body  $\rangle$

$\langle$  class modifiers  $\rangle ::= \langle$  class modifier  $\rangle | \langle$  class modifiers  $\rangle \langle$  class modifier  $\rangle$

$\langle$  class modifier  $\rangle ::=$  public | abstract | final

$\langle$  super  $\rangle ::=$  extends  $\langle$  class type  $\rangle$

$\langle$  interfaces  $\rangle ::=$  implements  $\langle$  interface type list  $\rangle$


$\langle$  interface type list  $\rangle ::= \langle$  interface type  $\rangle | \langle$  interface type list  $\rangle , \langle$  interface type  $\rangle$

6

# บทนำ

□ สำหรับกลุ่มภาษาที่เกี่ยวข้องกับ CFG จะถูกเรียกว่าภาษาไม่มีบริบท (context-free languages: CFL)

■ ซึ่งภาษา regular ก็จัดอยู่ในกลุ่มนี้เช่นกัน



7

# ตัวอย่างของ CFG

$A \rightarrow 0A1$

$A \rightarrow B$

$B \rightarrow \#$

- ไวยากรณ์ประกอบด้วยกฎของแทนที่ (substitution rules) หรืออาจเรียกว่ากฎการสร้าง (production rules)
- ส่วนกฎจะประกอบด้วย ตัวแปร (variables) และ สัญลักษณ์สิ้นสุด (terminal symbols)
- โดยที่จะมีตัวแปรหนึ่งตัวที่ถูกกำหนดให้เป็นตัวแปรเริ่มต้น (start variable) (มักจะตัวแปรที่จะด้านซ้ายมือของกฎที่อยู่บนสุด)

8

## การคำนวณ CFGs

- ในการใช้ CFG สำหรับอธิบายภาษาใดภาษาหนึ่งโดยการสร้างสตริงแต่ละตัวที่อยู่ในภาษานั้น จะมีกระบวนการดังนี้
  - เริ่มต้นจากเขียนตัวแปรเริ่มต้นก่อน
  - จากนั้นหากกฎที่มีตัวแปรที่ถูกเขียนไปแล้ว อยู่ทางด้านซ้ายมือของกฎ และจึงแทนตัวแปรนั้นด้วยส่วนของขวาของกฎ
  - วนซ้ำในขั้นตอนที่ 2 จึงกว่าจะไม่มีตัวแปรเหลืออยู่

9

## ตัวอย่างการคำนวณ

$$A \rightarrow 0A1 \quad (1)$$

$$A \rightarrow B \quad (2)$$

$$B \rightarrow \# \quad (3)$$


- ตัวอย่างการสร้างสตริง 000#111 สำหรับไวยากรณ์นี้

$$A \Rightarrow 0A1 \Rightarrow 00A11 \Rightarrow 000A111 \Rightarrow 000B111 \Rightarrow 000\#111$$

(1), (1), (1), (2), (3)

10

## ตัวอย่างการคำนวณ



เราสามารถใช้อุปกรณ์สร้างต้นไม้สำหรับแสดงการสร้างสตริงสำหรับไวยากรณ์

11

## CFGs

- สตริงทั้งหมดที่สามารถสร้างจากไวยากรณ์หนึ่ง เราจะเรียกว่าภาษาของไวยากรณ์นั้น (language of the grammar)
- เราเขียน  $L(G)$  สำหรับภาษาของไวยากรณ์  $G$
- จากตัวอย่างที่แล้ว แสดงว่า  $L(G)$  คือ  $\{0^n\#1^n \mid n \geq 0\}$
- สำหรับภาษาใดๆ ที่สามารถถูกสร้างโดย CFG จะถูกเรียกว่าภาษาไม่อิงบริบท (context-free language: CFL)

12

## CFGs

- เราสามารถเขียนย่อกฎที่มีตัวแปรฝั่งซ้ายเหมือนกันไว้เป็นกฎเดียวกันได้ ตัวอย่างเช่น

$$\begin{aligned} A &\rightarrow 0A1 \\ A &\rightarrow B \\ B &\rightarrow \# \\ &= \\ A &\rightarrow 0A1 \mid B \\ B &\rightarrow \# \end{aligned}$$

13

## นิยามของ CFG

A context-free grammar is a 4-tuple  $(V, \Sigma, S, P)$ , where

1.  $V$  is a finite set called the variables,
2.  $\Sigma$  is a finite set, disjoint from  $V$ , called the terminals,
3.  $S \in V$  is the start variable, and
4.  $P$  is a finite set of rules, with each rule being a variable and a string of variables and terminals  $(V \rightarrow (\Sigma \cup V)^*)$ .

14

## นิยามของ CFG

- ถ้า  $u, v$ , และ  $w$  เป็นสายลำดับของตัวแปรและตัวสิ้นสุด โดยที่  $A \rightarrow w$  เป็นกฎไวยากรณ์หนึ่ง
  - เราจะพูดว่า  $uAv$  *ผลิต*  $uwv$  โดยเขียนแทนว่า  $uAv \Rightarrow uwv$
- ถ้า  $u = v$  หรือ ถ้าลำดับ  $u_1, u_2, \dots, u_k$  มีอยู่สำหรับ  $k \geq 0$  และ

$$u \Rightarrow u_1 \Rightarrow u_2 \Rightarrow \dots \Rightarrow u_k \Rightarrow v$$

- เราจะพูดว่า  $u$  *กลายมาเป็น*  $v$  โดยเขียนแทนว่า  $u \stackrel{*}{\Rightarrow} v$
- ดังนั้นภาษาของไวยากรณ์คือ

$$\{w \in \Sigma^* \mid S \stackrel{*}{\Rightarrow} w\}$$

15

## ตัวอย่าง

$$A \rightarrow 0A1 \quad (1)$$

$$A \rightarrow B \quad (2)$$

$$B \rightarrow \# \quad (3)$$

- สำหรับไวยากรณ์นี้  $V = \{A, B\}$ ,  $\Sigma = \{0, 1, \#\}$ ,  $S = A$ , และ  $P$  คือกฎไวยากรณ์ทั้งสาม

16

## Derivations

สำหรับ CFG ที่ไม่ได้เป็น linear (ด้านขวาของกฎมีตัวแปรมากกว่าหนึ่งตัว) ในกรณีนี้เราต้องเลือกว่าตัวแปรไหนจะถูกแทนที่ก่อน

ตัวอย่างเช่น  $G = (\{A,B,S\}, \{a,b\}, S, P)$  โดยที่  $P$  คือ

1.  $S \rightarrow AB$
2.  $A \rightarrow aaA$
3.  $A \rightarrow \epsilon$
4.  $B \rightarrow Bb$
5.  $B \rightarrow \epsilon$

ซึ่ง  $L(G) = \{a^{2^n}b^m \mid n \geq 0, m \geq 0\}$  พิจารณาการแทนค่าตัวแปรต่อไปนี้

$$\begin{aligned} S &\xrightarrow{1} AB \xrightarrow{2} aaAA \xrightarrow{3} aaB \xrightarrow{4} aaBb \xrightarrow{5} aab \\ S &\xrightarrow{1} AB \xrightarrow{4} ABb \xrightarrow{2} aaABb \xrightarrow{5} aaAb \xrightarrow{3} aab \end{aligned}$$

17

## Derivations

- จากตัวอย่างที่แล้ว แสดงให้เห็นว่าสตริงเดียวกัน สามารถสร้างได้จากการใช้กฎชุดเดียวกัน แต่แตกต่างกันที่ลำดับการใช้กฎ
- ตามปกติ เพื่อง่ายต่อการพิจารณา เราจะกำหนดลำดับการแทนที่ที่กฎแบบตายตัว ซึ่งมี 2 แบบคือ
  - Leftmost derivation: แทนตัวแปรซ้ายสุดก่อนเสมอ
  - Rightmost derivation: แทนตัวแปรขวาสุดก่อนเสมอ

18

## ตัวอย่าง

จากกฎต่อไปนี้

$$\begin{aligned} S &\rightarrow aAB \\ A &\rightarrow bBb \\ B &\rightarrow A \mid \epsilon \end{aligned}$$

Leftmost derivation:

$$S \Rightarrow aAB \Rightarrow abBbB \Rightarrow abAbB \Rightarrow abbBbbB \Rightarrow abbbbB \Rightarrow abbbb$$

Rightmost derivation:


$$S \Rightarrow aAB \Rightarrow aA \Rightarrow abBb \Rightarrow abAb \Rightarrow abbBbb \Rightarrow abbbb$$

19

## Derivation Trees

- เราสามารถแสดง derivation ได้โดยใช้ derivation tree (parse tree) วิธีการนี้จะไม่สนใจในลำดับของการใช้กฎ

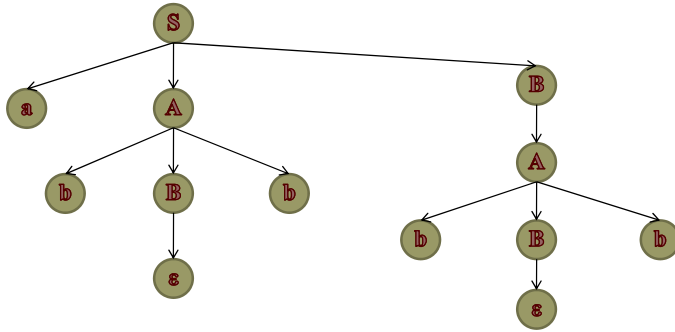
$$A \rightarrow abABc$$



20

## ตัวอย่าง

$S \rightarrow aAB$   
 $A \rightarrow bBb$   
 $B \rightarrow A \mid \epsilon$



$S \Rightarrow aAB \Rightarrow abBbB \Rightarrow abbB \Rightarrow abbA \Rightarrow abbbBb \Rightarrow abbbb$

21

## การออกแบบ Context-free Grammars

- เหมือนกับ FA คือ การออกแบบ CFG ต้องใช้ความคิดสร้างสรรค์
- ซึ่งแน่นอนว่า CFG ออกแบบยากกว่า FA
- เทคนิคต่อไปนี้อาจจะมีประโยชน์สำหรับการใช้ในการออกแบบ CFG

22

## การออกแบบ Context-free Grammars

1. ถ้า CFL เกิดจะการยูเนียนกันระหว่าง CFL หลายตัว การแก้ปัญหาทีละตัว “มักจะ” ง่ายกว่าการแก้ที่เดียวพร้อมกัน

$$\{0^n 1^n \mid n \geq 0\} \cup \{1^n 0^n \mid n \geq 0\}$$

$$S_1 = 0S_11 \mid \epsilon$$

$$S_2 = 1S_20 \mid \epsilon$$

$$S = S_1 \mid S_2$$

23

## การออกแบบ Context-free Grammars

2. ถ้า CFL ประกอบด้วยสตริงที่มีสตริงย่อยสองส่วนซึ่ง “เชื่อมโยงกัน” เราสามารถสร้าง CFG โดยใช้กฎที่อยู่ในรูป  $R \rightarrow uRv$

เช่นในภาษา  $\{0^n 1^n \mid n \geq 0\}$  สตริงย่อยส่วนที่เป็น 0 กับ ส่วนที่เป็น 1 “เชื่อมโยงกัน” ในแง่ที่ว่าทั้งสองส่วนต้องมีความยาวเท่ากัน

24

## การออกแบบ Context-free Grammars

3. ในภาษาที่มีความซับซ้อน สตริงอาจจะประกอบด้วยโครงสร้างหนึ่งที่ปรากฏซ้ำเป็นส่วนหนึ่งของโครงสร้างอื่น หรือ เป็นส่วนหนึ่งของโครงสร้างเดิม


ในกรณีนี้ ให้กำหนดตัวแปรที่แทนโครงสร้างที่ปรากฏซ้ำนั้นก่อน แล้วเขียนตัวแปรนั้นใส่ลงไปในกฎที่สัมพันธ์กับการเกิดซ้ำของโครงสร้างนี้

25

## การออกแบบ Context-free Grammars

a grammar for generating arithmetic expressions

$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle + \langle \text{TERM} \rangle \mid \langle \text{TERM} \rangle$   
 $\langle \text{TERM} \rangle \rightarrow \langle \text{TERM} \rangle \times \langle \text{FACTOR} \rangle \mid \langle \text{FACTOR} \rangle$   
 $\langle \text{FACTOR} \rangle \rightarrow (\langle \text{EXPR} \rangle) \mid a$



26

## แบบฝึกหัด

- จงหา CFG สำหรับภาษาต่อไปนี้ ( $n \geq 0, m \geq 0$ )
- $L = \{a^n b^m : n \leq m + 3\}$
  - $L = \{a^n b^m : n \neq m - 1\}$

27

## Parsing and Membership

- จากที่แล้วมาเราศึกษาไวยากรณ์ในแง่ของการสร้าง (generative aspect) คือสนใจว่าไวยากรณ์หนึ่งๆ สามารถสร้างสตริงอะไรได้บ้าง
- ในบางกรณี เราต้องการที่จะรู้ว่าสตริง  $w$  เป็นสมาชิกของ  $L(G)$  หรือไม่ (analytical aspect)
- บางครั้งเราอาจจะต้องรู้ด้วยว่า ถ้า  $w$  เป็นสมาชิกของ  $L(G)$  แล้วลำดับของการใช้กฎในการสร้าง  $w$  คืออะไร ซึ่งวิธีการดังกล่าวนี้จะถูกเรียกว่า “parsing”

28

## Exhaustive Search Parsing

วิธีเบื้องต้นที่สามารถทำได้ สำหรับการหา derivation (leftmost) ของสตริง  $w$  ที่เป็นสมาชิกของ  $L(G)$  ทำได้โดย

1. หากกฎทั้งหมดที่อยู่ในรูปแบบ  $S \rightarrow x$  โดยที่  $x$  เป็นลำดับของตัวแปรหรือตัวลึ้นสุด ถ้าไม่  $x$  ที่ตรงกับ  $w$  ให้ทำขั้นตอนต่อไป
2. แทนค่าตัวแปรซ้ายสุดใน  $x$  ทุกตัวด้วยกฎ ซึ่งผลลัพธ์ที่ได้ในขั้นตอนนี้คือ กลุ่มของ sentential forms ซึ่งอาจจะนำไปสู่  $w$
3. ถ้ายังไม่ได้  $w$  ให้วนซ้ำในขั้นตอนที่ 2 ไปเรื่อยๆ

29

## ตัวอย่าง

จากไวยากรณ์  $S \rightarrow SS \mid aSb \mid bSa \mid \epsilon$  จงหา derivation ของ  $aabb$

รอบแรก

1.  $S \Rightarrow SS$
2.  $S \Rightarrow aSb$
3.  $S \Rightarrow bSa$
4.  $S \Rightarrow \epsilon$

30

## ตัวอย่าง

$S \rightarrow SS \mid aSb \mid bSa \mid \epsilon$

รอบที่สอง ( $S \Rightarrow \underline{SS}$ )

1.  $S \Rightarrow \underline{SS} \Rightarrow SS$
2.  $S \Rightarrow \underline{SS} \Rightarrow aSbS$
3.  $S \Rightarrow \underline{SS} \Rightarrow bSaS$
4.  $S \Rightarrow \underline{SS} \Rightarrow S$

31

## ตัวอย่าง

$S \rightarrow SS \mid aSb \mid bSa \mid \epsilon$

รอบที่สอง ( $S \Rightarrow a\underline{S}b$ )

1.  $S \Rightarrow a\underline{S}b \Rightarrow aSSb$
2.  $S \Rightarrow a\underline{S}b \Rightarrow aaSbb$
3.  $S \Rightarrow a\underline{S}b \Rightarrow abSab$
4.  $S \Rightarrow a\underline{S}b \Rightarrow ab$

32



## ตัวอย่าง

ตัด sentential form ที่ไม่สามารถสร้าง aabb ได้ออก

รอบที่สอง

1.  $S \Rightarrow \underline{S}S \Rightarrow SS$
2.  $S \Rightarrow \underline{S}S \Rightarrow aSbS$
3.  $S \Rightarrow \underline{S}S \Rightarrow S$
4.  $S \Rightarrow a\underline{S}b \Rightarrow aSSb$
5.  $S \Rightarrow a\underline{S}b \Rightarrow aaSbb$

33

## ตัวอย่าง

จาก sentential form ที่ 5 เราสามารถสร้าง aabb ได้

$$S \Rightarrow a\underline{S}b \Rightarrow aaSbb \Rightarrow \epsilon$$

แต่ถ้า exhaustive search parsing มีข้อเสียคือใช้เวลาในการประมวลผลนาน และเป็นไปได้ที่การค้นหาจะไม่อยู่ทำงาน (nontermination) ในกรณีที่สตรึงไม่ได้อยู่ในภาษาของไวยากรณ์นั้น

34

## ปัญหาการไม่หยุดทำงาน (nontermination)

- ถ้าพิจารณาจากตัวอย่าง เราจะเห็นว่าปัญหานี้เกิดจากที่กฎบางอัน ทำให้ sentential form มีขนาดลดลง นั่นคือกฎ

$$S \rightarrow \epsilon$$

- จริงๆ แล้วกฎที่ทำให้ปัญหามีอยู่สองแบบคือ (โดยที่ A และ B คือหนึ่งตัวแปร)

1.  $A \rightarrow \epsilon$
2.  $A \rightarrow B$

35

## Exhaustive Search Parsing

- ถ้าในกฎไวยากรณ์ไม่มีกฎทั้งสองแบบนี้

1.  $A \rightarrow \epsilon$
2.  $A \rightarrow B$

- exhaustive search parsing จะสามารถหาได้ว่าสตรึงใดอยู่ในภาษาของไวยากรณ์หรือไม่ และสามารถหา derivation ของสตรึงที่อยู่ในภาษาของไวยากรณ์ได้โดยทำงานไม่เกิน  $2 \times |w|$  รอบของการทำงาน

- ในกรณีเลวร้ายสุดคือในรอบที่  $w$  มี sentential forms ที่เป็นตัวแปรทั้งหมด ดังนั้นต้องทำอีก  $w$  รอบ ในการแทนค่าตัวแปรทั้งหมด

36

## Exhaustive Search Parsing

### การวิเคราะห์ขอบบนของการคำนวณ (Big-O)

- ถ้า  $|P|$  คือจำนวนของกฎไวยากรณ์ ในรอบแรกจะเกิด **sentential form** ไม่เกิน  $|P|$  สำหรับรอบที่สองจะไม่เกิน  $|P|^2$
- เราทราบแล้วว่าการคำนวณจะไม่เกิน  $2|w|$  รอบ ดังนั้นจำนวน **sentential form** ทั้งหมดจะไม่เกิน
$$|P| + |P|^2 + |P|^3 + \dots + |P|^{2|w|}$$
- ดังนั้นขอบบนของการคำนวณ คือ  $O(|P|^{2|w|+1})$

37

## ความกำกวมของไวยากรณ์ (Ambiguity)

- ในบางครั้งไวยากรณ์หนึ่งสามารถสร้างสตริงหนึ่ง ได้หลายวิธี
  - หนึ่งสตริงสามารถเกิดได้จากหลาย **derivation trees**
  - หรือเรียกว่า หนึ่งสตริงมีได้หลายความหมาย
- ซึ่งลักษณะเช่นนี้ อาจจะไม่เป็นที่ต้องการสำหรับงานบางอย่าง เช่น โปรแกรมภาษา (programming languages)

38

## ความกำกวมของไวยากรณ์ (Ambiguity)

- ถ้าไวยากรณ์หนึ่งสามารถสร้างสตริงหนึ่งได้หลายวิธี
  - เราเรียกว่า สตริงนั้นถูกสร้างอย่างกำกวมในไวยากรณ์นี้
  - มีหลาย **derivation (parse) trees** ที่แตกต่างกัน ไม่ใช่ หลาย **derivations** ที่แตกต่างกัน
- ถ้าไวยากรณ์หนึ่งสามารถสร้างสตริงอย่างกำกวมได้
  - เราเรียกว่า ไวยากรณ์นั้นกำกวม (**ambiguous**)

39


## ตัวอย่าง

พิจารณาไวยากรณ์  $G$  ดังนี้

$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle + \langle \text{EXPR} \rangle$

$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle \times \langle \text{EXPR} \rangle$

$\langle \text{EXPR} \rangle \rightarrow (\langle \text{EXPR} \rangle) | a$



40

## ความกำกวมของไวยากรณ์ (Ambiguity)

เรานิยามความกำกวมได้ดังนี้

- A context-free grammar  $G$  is said to be ambiguous if there exists some  $w \in L(G)$  that has at least two distinct derivation trees.

41

## แบบฝึกหัด

- จงแสดงว่าไวยากรณ์ต่อไปนี้กำกวม และ จงหาสร้างไวยากรณ์ที่ไม่กำกวมสำหรับภาษาเดียวกัน

$$S \rightarrow AB \mid aaB$$

$$A \rightarrow a \mid Aa$$

$$B \rightarrow b$$

42

## Simplification of Context-Free Grammars and Normal Forms

นำเสนอโดย

ดร.สุธี สดุดประเสริฐ

43

## Methods for Transforming Grammars

- เราได้ทราบแล้วว่า สตริงว่าง ทำให้การปัญหาในการคำนวณเพื่อหาว่า สตริงหนึ่งเป็นสมาชิกในภาษาของไวยากรณ์หนึ่งหรือเปล่า
- ในทางทฤษฎี สตริงว่าง มีความสำคัญในการพิสูจน์ทฤษฎีบทต่างๆ แต่ในทางปฏิบัติ เราไม่ต้องการที่จะนำสตริงว่างมาพิจารณา

44

## Methods for Transforming Grammars

- จริงๆ แล้ว การลบสตริงว่างออกจากสมาชิกของภาษาใดภาษาหนึ่ง นั้น ไม่ทำให้สูญเสียคุณสมบัติทั่วไปของภาษานั้นไป เพราะว่า ถ้ามี ไวยากรณ์  $G = (V, T, S, P)$  ซึ่ง  $L - \{\epsilon\}$
- เราสามารถไวยากรณ์ใหม่ที่มี สตริงว่างเป็นสมาชิกได้โดยเปลี่ยนให้  $S_0$  เป็นตัวแปรเริ่มต้นแทน  $S$  และเพิ่มกฎ  $S_0 \rightarrow S \mid \epsilon$  เข้าไป
- เพื่อต้องการทำความเข้าใจ (ถ้าไม่ได้ชี้เฉพาะเจาะจงลงไป) ภาษาที่เราจะพิจารณาต่อไปในบทนี้ จะเป็นภาษาที่ไม่สตริงว่างเป็นสมาชิก ( $\epsilon$ -free languages)

45

## การลบกฎที่ไร้ประโยชน์

- กฎที่ไร้ประโยชน์คือกฎที่ไม่มีทางถูกใช้ในสร้างสตริงใดๆ ในภาษาของไวยากรณ์นั้น
- ตัวอย่างเช่น
$$S \rightarrow aSb \mid \epsilon \mid A$$
$$A \rightarrow aA$$
กฎ  $S \rightarrow A$  และ  $A \rightarrow aA$  เป็นกฎที่ไร้ประโยชน์ เพราะว่าถ้า  $A$  ปรากฏใน **sentential form** แล้ว จะไม่มีทางที่จะสร้างสตริงอะไรได้เลย ( $A$  ไม่สามารถเปลี่ยนเป็นตัวสิ้นสุดได้)

46

## การลบกฎที่ไร้ประโยชน์

### นิยาม

ถ้า  $G = (V, T, S, P)$  เป็น CFG และตัวแปร  $A \in V$  จะมี ประโยชน์ ก็ต่อเมื่อ มีอย่างหนึ่งสตริง  $w \in L(G)$  ที่

$$S \xRightarrow{*} xAy \xRightarrow{*} w$$

เมื่อ  $x, y$  in  $(V \cup T)^*$

และถ้าตัวแปรใดไม่เป็นตัวแปรที่มีประโยชน์ ตัวแปรนั้น คือ ไร้ประโยชน์

47

## การลบกฎที่ไร้ประโยชน์

- กฎที่ไร้ประโยชน์ เกิดจากตัวแปรที่ไร้ประโยชน์ ซึ่งมีสาเหตุเกิดได้ 2 กรณี คือ
  1. ตัวแปรนั้นไม่สามารถแปลงเป็นตัวสิ้นสุดได้
  2. ตัวแปรนั้นไม่สามารถเข้าถึงได้จากตัวแปรเริ่มต้น

48


## การลบกฎที่ไร้ประโยชน์

- สำหรับกรณีที่ 2 คือตัวแปรที่ไม่สามารถเข้าถึงได้จากตัวแปรเริ่มต้น เราสามารถเขียน dependency graph เพื่อช่วยในการวิเคราะห์ได้เช่น

$$S \rightarrow aS \mid A$$

$$A \rightarrow a$$

$$B \rightarrow aa$$



49

## การลบกฎที่สร้างสตริงว่าง

ถ้าไวยากรณ์หนึ่งสร้างภาษาที่ไม่มีสตริงว่างเป็นสมาชิก แต่ยังมีกฎที่สร้างสตริงว่างอยู่ เราสามารถลบกฎเหล่านั้นทิ้งได้ โดยวิธีการต่อไปนี้

1. ลบกฎที่อยู่ในรูปแบบ  $A \rightarrow \epsilon$  ทิ้งทั้งหมด
2. หากกฎ  $A \rightarrow \epsilon$  ทั้งหมดแล้วเก็บ A ไว้ใน  $V_N$
3. ทำซ้ำขั้นตอนต่อไปนี จนกว่าจะไม่มีตัวแปรที่ถูกเพิ่มไปใน  $V_N$ 
  1. สำหรับกฎ  $B \rightarrow A_1A_2\dots A_n$  โดย  $A_1A_2\dots A_n$  อยู่ใน  $V_N$  ให้เพิ่ม B เข้าไปใน  $V_N$
4. หากกฎ  $A \rightarrow x_1x_2\dots x_m$ ,  $m \geq 1$  และ  $x_i \in V \cup T$  จากนั้นให้แทนตัวแปรที่อยู่ใน  $V_N$  ด้วย  $\epsilon$  ในทุกๆ แบบ

50

## การลบกฎที่สร้างสตริงว่าง

$$S \rightarrow ABaC$$

$$A \rightarrow BC$$

$$B \rightarrow b \mid \epsilon$$

$$C \rightarrow D \mid \epsilon$$

$$D \rightarrow d$$

51

## การลบกฎที่สร้างสตริงว่าง

$$S \rightarrow ABaC$$

$$A \rightarrow BC$$

$$B \rightarrow b \mid \epsilon$$

$$C \rightarrow D \mid \epsilon$$

$$D \rightarrow d$$

$$V_N = \{B, C, A\}$$

52

## การลดทอนที่สร้างสตริงว่าง

$$S \rightarrow ABaC \mid BaC \mid AaC \mid ABa \mid aC \mid Aa \mid Ba \mid a$$

$$A \rightarrow BC \mid B \mid C$$

$$B \rightarrow b$$

$$C \rightarrow D$$

$$D \rightarrow d$$

$$V_N = \{B, C, A\}$$

53

## การลดทอนหนึ่งหน่วย (unit-production)

### นิยาม

กฎของไวยากรณ์ CFG ที่อยู่ในรูปแบบ

$$A \rightarrow B$$

โดยที่  $A, B \in V$  จะถูกเรียกว่า กฎหนึ่งหน่วย

54

## การลดทอนหนึ่งหน่วย (unit-production)

ถ้าไวยากรณ์หนึ่งสร้างภาษาที่ไม่มีสตริงว่างเป็นสมาชิก แต่ยังมีกฎหนึ่งหน่วยอยู่ เราสามารถลดทอนเหล่านั้นทิ้งได้ โดยวิธีการต่อไปนี้

1. ลดทอนหนึ่งหน่วยทิ้งทั้งหมด
2. สร้าง dependency graph สำหรับกฎหนึ่งหน่วย เพื่อช่วยในการทำงาน  $A \xRightarrow{*} B$
3. สำหรับทุกๆ  $A \xRightarrow{*} B$  ให้เพิ่มกฎ  $A \rightarrow y_1|y_2|\dots|y_n$  โดยที่  $B \rightarrow y_1|y_2|\dots|y_n$  ( $B$  ไม่รวมส่วนที่เป็นกฎหนึ่งหน่วย)

55

## การลดทอนหนึ่งหน่วย (unit-production)


พิจารณากฎการผลิตต่อไปนี้

$$S \rightarrow Aa \mid B$$

$$A \rightarrow a \mid bc \mid B$$

$$B \rightarrow A \mid bb$$


ต้องเพิ่มบทสรุป



56

## การลบกฎหนึ่งหน่วย (unit-production)


$$\begin{aligned} S &\rightarrow Aa \\ A &\rightarrow a \mid bc \\ B &\rightarrow bb \end{aligned}$$



57

## การลบกฎหนึ่งหน่วย (unit-production)

$$\begin{aligned} S &\rightarrow Aa \mid a \mid bc \mid bb \\ A &\rightarrow a \mid bc \\ B &\rightarrow bb \end{aligned}$$




$$\begin{aligned} S &\xRightarrow{*} A \\ S &\xRightarrow{*} B \end{aligned}$$

58

## การลบกฎหนึ่งหน่วย (unit-production)

$$\begin{aligned} S &\rightarrow Aa \mid a \mid bc \mid bb \\ A &\rightarrow a \mid bc \mid bb \\ B &\rightarrow bb \end{aligned}$$




$$A \xRightarrow{*} B$$

59

## การลบกฎหนึ่งหน่วย (unit-production)

$$\begin{aligned} S &\rightarrow Aa \mid a \mid bc \mid bb \\ A &\rightarrow a \mid bc \mid bb \\ B &\rightarrow bb \mid a \mid bc \end{aligned}$$



$$B \xRightarrow{*} A$$

60

## Two Important Normal Forms

- รูปแบบปกติของ CFG มีอยู่หลายรูปแบบ เนื่องจากมีการนำ CFG ไปประยุกต์และวิจัยกันอย่างกว้างขวาง เช่น
  - Backus-Naur form (BNF)
  - Chomsky normal form (CNF)
  - Kuroda normal form (KNF)
  - Greibach normal form (GNF)
- ในที่นี้เราจะศึกษา 2 ตัว คือ Chomsky normal form และ Greibach normal form

61

## Chomsky Normal Form

- ในการนำ CFG ไปใช้งาน ในบางกรณีหากไวยากรณ์นั้นอยู่ในรูปแบบพิเศษ เราจะสามารถใช้งานไวยากรณ์ในสะดวกขึ้น
- Chomsky normal form เป็นรูปแบบพิเศษหนึ่งที่น่าสนใจ และมีประโยชน์ในการนำไปใช้งาน เช่น การหา parse trees โดยใช้ CYK algorithm

62

## Chomsky Normal Form

CFG จะอยู่ในรูปแบบ Chomsky normal form ถ้าทุกๆ กฎไวยากรณ์อยู่ในรูปแบบต่อไปนี้

$$A \rightarrow BC$$

$$A \rightarrow a$$

$$S \rightarrow \epsilon$$

โดยที่  $a$  คือตัวสิ้นสุดใดๆ และ  $A, B,$  และ  $C$  คือ ตัวแปรใดๆ ยกเว้น แต่  $B$  และ  $C$  ห้ามเป็นตัวแปรเริ่มต้น และ  $S$  คือ ตัวแปรเริ่มต้น

63

## Chomsky Normal Form

- วิธีการแปลง CFG ใดๆ ให้อยู่ในรูปแบบ Chomsky normal form สามารถทำได้ดังนี้
  - สร้างตัวแปรเริ่มต้นใหม่ ( $S_0 \rightarrow S$ )
  - ลบกฎที่สร้างสตริงว่าง ( $A \rightarrow \epsilon$ )
  - ลบกฎหนึ่งหน่วย ( $A \rightarrow B$ )
  - แปลงกฎที่เหลือให้อยู่ในรูปแบบที่เหมาะสม

64



## ตัวอย่าง

$$\begin{aligned} S &\rightarrow ASA \mid aB \\ A &\rightarrow B \mid S \\ B &\rightarrow b \mid \epsilon \end{aligned}$$

65

## ตัวอย่าง

สร้างตัวแปรเริ่มต้นใหม่

$$\begin{aligned} S_0 &\rightarrow S \\ S &\rightarrow ASA \mid aB \\ A &\rightarrow B \mid S \\ B &\rightarrow b \mid \epsilon \end{aligned}$$

66

## ตัวอย่าง

ลบกฎที่สร้างสตริงว่าง

$$\begin{array}{ll} S_0 \rightarrow S & S_0 \rightarrow S \\ S \rightarrow ASA \mid aB & S \rightarrow ASA \mid aB \mid SA \mid AS \mid S \mid a \\ A \rightarrow B \mid S & A \rightarrow B \mid S \\ B \rightarrow b \mid \epsilon & B \rightarrow b \end{array}$$


$$V_N = \{A, B\}$$

67

## ตัวอย่าง

ลบกฎหนึ่งหน่วย

$$\begin{aligned} S_0 &\rightarrow S \\ S &\rightarrow ASA \mid aB \mid SA \mid AS \mid S \mid a \\ A &\rightarrow B \mid S \\ B &\rightarrow b \end{aligned}$$



68

## ตัวอย่าง

ลบกฎหนึ่งหน่วย

$S_0 \rightarrow$

$S \rightarrow ASA \mid aB \mid SA \mid AS \mid a$

$A \rightarrow$

$B \rightarrow b$



69

## ตัวอย่าง

ลบกฎหนึ่งหน่วย

$S_0 \rightarrow ASA \mid aB \mid SA \mid AS \mid a$

$S \rightarrow ASA \mid aB \mid SA \mid AS \mid a$

$A \rightarrow ASA \mid aB \mid SA \mid AS \mid a \mid b$

$B \rightarrow b$



70

## ตัวอย่าง

แปลงกฎที่เหลือให้อยู่ในรูปแบบที่เหมาะสม

$S_0 \rightarrow \underline{ASA} \mid \underline{aB} \mid a \mid SA \mid AS$

$S \rightarrow \underline{ASA} \mid \underline{aB} \mid a \mid SA \mid AS$

$A \rightarrow \underline{ASA} \mid \underline{aB} \mid a \mid SA \mid AS \mid b$

$B \rightarrow b$

71

## ตัวอย่าง

แปลงกฎที่เหลือให้อยู่ในรูปแบบที่เหมาะสม

$S_0 \rightarrow AA_1 \mid UB \mid a \mid SA \mid AS$

$S \rightarrow AA_1 \mid UB \mid a \mid SA \mid AS$

$A \rightarrow AA_1 \mid UB \mid a \mid SA \mid AS \mid b$

$B \rightarrow b$

$A_1 \rightarrow SA$

$U \rightarrow a$

72

## Greibach normal form

- การแปลง CFG ใดๆ ให้อยู่ใน GNF ไม่ใช่เรื่องยาก ตรงไปตรงมา
- GNF มีบทบาทสำคัญในการพิสูจน์ทฤษฎีบทบางบท

73

## Greibach normal form

CFG จะอยู่ในรูปแบบ Greibach normal form ถ้าทุกๆ กฎไวยากรณ์อยู่ในรูปแบบต่อไปนี้

$$A \rightarrow ax$$

โดยที่  $a \in T$  และ  $x \in V^*$

74

## ตัวอย่าง

จงแปลงไวยากรณ์ต่อไปนี้ให้อยู่ในรูปแบบ GNF

$$S \rightarrow AB \quad (1)$$

$$A \rightarrow aA \mid bB \mid b \quad (2)$$

$$B \rightarrow b \quad (3)$$

เราสามารถแปลงได้โดยการแทน (2) ใน (1)

75

## ตัวอย่าง

ผลลัพธ์จะได้

$$S \rightarrow \underline{a}AB \mid \underline{b}BB \mid \underline{b}B$$

$$\underline{A} \rightarrow aA \mid bB \mid b$$

$$B \rightarrow b$$

76

## ตัวอย่าง

จงแปลงไวยากรณ์ต่อไปนี้ให้อยู่ในรูปแบบ GNF

$$S \rightarrow abSb \mid aa$$

ในกรณีนี้ ให้สร้างตัวแปรใหม่เพื่อ แทน a และ b

$$A \rightarrow a$$

$$B \rightarrow b$$

77

## ตัวอย่าง

$$S \rightarrow abSb \mid aa$$

$$A \rightarrow a$$

$$B \rightarrow b$$

ผลลัพธ์จะได้

$$S \rightarrow a\underline{B}S\underline{B} \mid a\underline{A}$$

$$A \rightarrow a$$

$$B \rightarrow b$$

78

## Efficient CFG Parsing Techniques


- Bottom-up parsing
  - CYK algorithm
  
- Top-down parsing
  - Earley parser

79

## Bottom-up

$$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$$


“aabbb”



80

## Bottom-up


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$   
“aabbb”



81

## Bottom-up


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$   
“aabbb”



82

## Bottom-up


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$   
“aabbb”



83

## Bottom-up


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$   
“aabbb”



84

## Bottom-up


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$



85

## Top-down


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$



86

## Top-down


$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$



87

## Top-down

$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$




88

## Top-down

$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$

“aabb”




89

## Top-down

$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$

“aabb”




90

## Top-down

$S \rightarrow AB, A \rightarrow BB \mid a, B \rightarrow AB \mid b$

“aabb”



91

## The CYK algorithm

- ❑ CYK ย่อมาจาก Cocke–Younger–Kasami
- ❑ เป็นวิธีการหา parse trees สำหรับ CFG โดยใช้แนวคิดแบบ bottom-up
- ❑ จำเป็นต้องแปลงไวยากรณ์ให้อยู่ในรูปแบบ Chomsky normal form (CNF) ก่อน
- ❑ worst case running time =  $O(|G| \times n^3)$  โดยที่  $n$  คือความยาวของสตริง และ  $|G|$  คือขนาดของ CNF

92

# The CYK algorithm

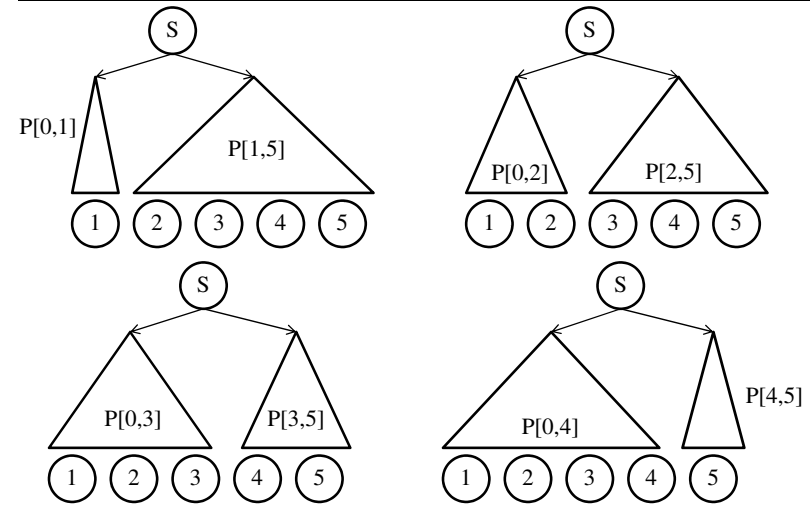
## หลักการ

พิจารณาทุกๆ สตริงย่อยของอินพุตว่า แต่ละสตริงย่อยสามารถถูกสร้างขึ้น จากกฎใดได้บ้าง จากนั้นจึงบันทึกข้อมูลไว้ใน  $P[i,j]$  โดยที่  $i$  และ  $j$  ไว้บอกตำแหน่งของสตริงย่อยในสตริง

การพิจารณาจะเริ่มจากสตริงย่อยขนาดเล็กที่สุดก่อน แล้วจะค่อยๆ เพิ่มขนาดของสตริงย่อยขึ้นไป โดยที่จะนำส่วนของที่ถูกพิจารณาไว้ก่อน แล้วมาใช้พิจารณาพร้อมด้วยดังนี้

$$P[i,j] \bullet P[j,k] = P[i,k]$$

# The CYK algorithm



# The CYK algorithm

ให้ไวยากรณ์  $G_1$  คือ

$$S \rightarrow AB$$

$$A \rightarrow BB \mid a$$

$$B \rightarrow AB \mid b$$

“aabbba” สามารถสร้างจาก  $G_1$  ได้หรือไม่

# The CYK algorithm

length					
5					
4	0-5				
3	0-4	1-5			
2	0-3	1-4	2-5		
1	0-2	1-3	2-4	3-5	
	0-1	1-2	2-3	3-4	4-5
	a	a	b	b	b



# The CYK algorithm

length					
5	0-5				
4	0-4		1-5		
3	0-3	1-4		2-5	
2	0-2	1-3		2-4	
1	0-1	1-2	2-3	3-4	4-5
	A	A	B	B	B
	a	a	b	b	b

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

97

# The CYK algorithm

length					
5	0-5				
4	0-4		1-5		
3	0-3	1-4		2-5	
2	$\emptyset$	S,B	A	A	
1	A	A	B	B	B
	a	a	b	b	b

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

98

# The CYK algorithm

length					
5	0-5				
4	0-4		1-5		
3	S,B	A	S,B		
2	$\emptyset$	S,B	A	A	
1	A	A	B	B	B
	a	a	b	b	b

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

99

# The CYK algorithm

length					
5	0-5				
4	A	S,B			
3	S,B	A	S,B		
2	$\emptyset$	S,B	A	A	
1	A	A	B	B	B
	a	a	b	b	b

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

100

## The CYK algorithm

length						
5	S,B					
4	A	S,B				
3	S,B	A	S,B			
2	∅	S,B	A	A		
1	A	A	B	B	B	
	a	a	b	b	b	101

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

## The CYK algorithm

- หาก  $S$  ปรากฏใน  $P[1,n]$  โดยที่  $n$  คือความยาวของอินพุต แสดงว่าอินพุตนั้นสามารถถูกสร้างได้โดยไวยากรณ์นั้น
- ดังนั้นจึงสรุปได้ว่า **aabbb** สามารถสร้างได้โดย  $G_1$
- หากต้องการหา **parse trees** สำหรับการสร้างสตริง สามารถทำได้โดยเพิ่มตาราง  $B[i,j]$  (backpointers) เพื่อบันทึกวิธีการสร้างข้อมูลในตำแหน่ง  $i,j$  ของตาราง  $P[i,j]$

102

## The CYK algorithm

length						
5		backpointers				
4	0-5					
3	0-4	1-5				
2	0-3	1-4	2-5			
1	0-2	1-3	2-4	3-5		
	0-1	1-2	2-3	3-4	4-5	
	a	a	b	b	b	103

## The CYK algorithm

length						
5		backpointers				
4	0-5					
3	0-4	1-5				
2	0-3	1-4	2-5			
1	0-2	1-3	2-4	3-5		
	A	A	B	B	B	
	a	a	b	b	b	104

$S \rightarrow AB$   
 $A \rightarrow BB$   
 $B \rightarrow AB$   
 $A \rightarrow a$   
 $B \rightarrow b$

# The CYK algorithm

length						
5		backpointers				$S \rightarrow AB$ $A \rightarrow BB$ $B \rightarrow AB$ $A \rightarrow a$ $B \rightarrow b$
4	0-5					
3	0-4	1-5				
2	0-3	1-4	2-5			
1	0-2	S,B (A,2,B)	A (B,3,B)	A (B,4,B)		
	0-1	A	B	B	B	
		a	a	b	b	
					105	

# The CYK algorithm

length						
5		backpointers				$S \rightarrow AB$ $A \rightarrow BB$ $B \rightarrow AB$ $A \rightarrow a$ $B \rightarrow b$
4	0-5					
3	0-4	1-5				
2	0-3	S,B (A,1,B)	A (B,3,B)	S,B (A,4,B)		
1	0-2	∅	S,B (A,2,B)	A (B,3,B)	A (B,4,B)	
	0-1	A	A	B	B	
		a	a	b	b	
					106	

# The CYK algorithm

length						
5		backpointers				$S \rightarrow AB$ $A \rightarrow BB$ $B \rightarrow AB$ $A \rightarrow a$ $B \rightarrow b$
4	0-5					
3	0-4	(A,4,B)				
2	0-3	S,B (A,1,B)	A (B,3,B)	S,B (A,4,B)		
1	0-2	∅	S,B (A,2,B)	A (B,3,B)	A (B,4,B)	
	0-1	A	A	B	B	
		a	a	b	b	
					107	

# The CYK algorithm

length						
5		backpointers				$S \rightarrow AB$ $A \rightarrow BB$ $B \rightarrow AB$ $A \rightarrow a$ $B \rightarrow b$
4	0-5	S,B (A,1,B)				
3	0-4	(A,4,B)				
2	0-3	A (B,3,B)	S,B (A,2,B)			
1	0-2	S,B (A,1,B)	A (B,3,B)	S,B (A,4,B)		
	0-1	∅	S,B (A,2,B)	A (B,3,B)	A (B,4,B)	
		A	A	B	B	
		a	a	b	b	
					108	

## The CYK algorithm

length	backpointers				
5	S,B (A,1,B) (A,4,B)				
4	A (B,3,B) 0-4	S,B (A,2,B) (A,4,B) 1-5			
3	S,B (A,1,B) 0-3	A (B,3,B) 1-4	S,B (A,4,B) 2-5		
2	∅ 0-2	S,B (A,2,B) 1-3	A (B,3,B) 2-4	A (B,4,B) 3-5	
1	A 0-1	A 1-2	B 2-3	B 3-4	B 4-5
	a	a	b	b	b

109

## Earley Parser

- วิธีการหา parse trees จากไวยากรณ์ CFG ซึ่งจัดอยู่ในรูปแบบ chart parser ซึ่งคิดค้นโดย Jay Earley (1970)
- ใช้แนวคิดแบบ top-down ในการสร้าง parse trees (การคำนวณจะทำเฉพาะรูปแบบที่สามารถสร้างได้จาก S เท่านั้น)
- สามารถใช้ได้สำหรับไวยากรณ์ CFG ทุกรูปแบบ ไม่ต้องแปลงให้อยู่ในรูปแบบพิเศษก่อน
- Worst case running time =  $O(n^3)$
- ถ้าสำหรับไวยากรณ์ที่ไม่กำกวม จะเป็น  $O(n^2)$

110

## Earley Parser

### หลักการ

การทำงานจะแบ่งเป็นสถานะ โดยที่แต่ละสถานะจะแสดงถึงจำนวนอินพุตที่อ่านไปแล้ว เช่น อินพุตคือ aab สถานะการทำงานจะมี 4 สถานะ คือ

1. •aab (ยังไม่เริ่มอ่าน)
2. a•ab (อ่านไปแล้วหนึ่งตัว)
3. aa•b (อ่านไปแล้วสองตัว)
4. aab• (อ่านไปแล้วสามตัว)

111

## Earley Parser

### หลักการ (ต่อ)

ในแต่ละสถานะจะประกอบด้วยข้อมูลคู่ลำดับของ item และ origin position ซึ่งเรียกว่า suffix

- item คือ กฎไวยากรณ์ที่เพิ่มสัญลักษณ์ • เข้าไป (หนึ่งตัวในตำแหน่งใดก็ได้) ในฝั่งขวาของกฎ เช่น  $B \rightarrow \bullet AB$  หรือ  $B \rightarrow A \bullet B$  หรือ  $B \rightarrow AB \bullet$
- origin position คือ เลขที่แทนค่าสถานะ จริงๆแล้วจะให้เลขอะไรก็ได้ที่ไม่ซ้ำกัน

112

## Earley Parser

### หลักการ (ต่อ)

มีฟังก์ชัน 3 อัน ที่ใช้ในการเพิ่ม suffix เข้าไปในสถานะ คือ

- Prediction
- Scanner
- Completion

113

## Earley Parser

- Prediction จะถูกใช้งานเมื่อมี item ของ suffix ใดๆ ที่มี • อยู่หน้าตัวแปร โดยการเพิ่ม suffix ใหม่เข้าไปในสถานะปัจจุบัน  
ณ. สถานะ  $t$  ใดๆ ถ้ามี suffix ดังนี้

$M \rightarrow x \bullet N y, n$  : เมื่อ predict จะเพิ่ม suffix ใหม่คือ

$N \rightarrow \bullet z, t$  เข้าไปในสถานะ  $t$

$M, N \in V, x, y \in (V \cup T)^*$  และ  $z \in (V \cup T)^+$

114

## Earley Parser

- Scanner จะถูกใช้งานเมื่อมี item ของ suffix ใดๆ ที่มี • อยู่หน้าตัวสิ้นสุด (terminal) และตัวสิ้นสุดนั้น สอดคล้องกับอินพุตของสถานะปัจจุบัน โดยจะเพิ่ม suffix ใหม่ในสถานะถัดไป

ณ. สถานะ  $t : a \bullet s b$

มี suffix คือ  $M \rightarrow x \bullet s y, n$  เมื่อ scan จะเพิ่ม

$M \rightarrow x s \bullet y, n$  ในสถานะ  $t+1$

$M \in V, s \in T, a, b \in T^*$ , และ  $x, y \in (V \cup T)^*$

115

## Earley Parser

- Completion จะถูกใช้งานเมื่อมี item ของ suffix ใดๆ ที่มี • อยู่ในตำแหน่งสุดท้ายของกฎ  
ณ. สถานะ  $t$  ใดๆ ถ้ามี suffix ดังนี้

$M \rightarrow z \bullet, n$  และ

ใน สถานะ  $n$  มี suffix ดังนี้

$L \rightarrow x \bullet M y, s$  ให้เพิ่ม  $L \rightarrow x M \bullet y, s$  ในสถานะ  $t$

$L, M, N \in V, x, y, z \in (V \cup T)^*$

116

# Earley Parser

ให้ไวยากรณ์  $G_1$  คือ

$$S \rightarrow AB$$

$$A \rightarrow BB \mid a$$

$$B \rightarrow AB \mid b$$

“aabb” สามารถสร้างจาก  $G_1$  ได้หรือไม่

117

# Earley Parser

เริ่มต้นที่สถานะ 0 คือ  $\bullet aabbb$

$S(0) : \bullet aabbb$

1.  $P \rightarrow \bullet S, 0$  #suffix เริ่มต้น
2.  $S \rightarrow \bullet AB, 0$  #predict จาก 1.
3.  $A \rightarrow \bullet BB, 0$  #predict จาก 2.
4.  $A \rightarrow \bullet a, 0$  #predict จาก 2.
5.  $B \rightarrow \bullet AB, 0$  #predict จาก 3.
6.  $B \rightarrow \bullet b, 0$  #predict จาก 3.

$S(0,4)$  ตรงกับเงื่อนไขของ scanner

118

# Earley Parser

$S(1) : a \bullet abbb$

1.  $A \rightarrow a \bullet, 0$  #scan จาก  $S(0,4)$

# เมื่อ  $\bullet$  ไปอยู่ตำแหน่งท้ายสุด เข้าเงื่อนไข completion

2.  $S \rightarrow A \bullet B, 0$  #complete จาก  $S(0,2)$
3.  $B \rightarrow A \bullet B, 0$  #complete จาก  $S(0,5)$
4.  $B \rightarrow \bullet AB, 1$  #predict จาก 2,3.
5.  $B \rightarrow \bullet b, 1$  #predict จาก 2,3.
6.  $A \rightarrow \bullet BB, 1$  #predict จาก 4.
7.  $A \rightarrow \bullet a, 1$  #predict จาก 4.

$S(0) : \bullet aabbb$   
2.  $S \rightarrow \bullet AB, 0$  #predict จาก 1.  
5.  $B \rightarrow \bullet AB, 0$  #predict จาก 3.

$B \rightarrow AB \mid b$

$A \rightarrow BB \mid a$

$S(1,7)$  ตรงกับเงื่อนไขของ scanner

119

# Earley Parser

$S(2) : aa \bullet bbb$

1.  $A \rightarrow a \bullet, 1$  #scan จาก  $S(1,7)$
2.  $B \rightarrow A \bullet B, 1$  #complete จาก  $S(1,4)$
3.  $B \rightarrow \bullet AB, 2$  #predict จาก 2.
4.  $B \rightarrow \bullet b, 2$  #predict จาก 2.
5.  $A \rightarrow \bullet BB, 2$  #predict จาก 3.
6.  $A \rightarrow \bullet a, 2$  #predict จาก 3.

$S(1)$   
4.  $B \rightarrow \bullet AB, 1$  #predict จาก 2,3

$B \rightarrow AB \mid b$

$A \rightarrow BB \mid a$

$S(2,4)$  ตรงกับเงื่อนไขของ scanner

120

# Earley Parser

S(3) : aab•bb

1. B → b•,2 # scan จาก S(2,4)
2. B → AB•,1 # complete จาก S(2,2)
3. A → B•B,2 # complete จาก S(2,5)
4. S → AB•,0 # complete จาก S(1,2)
5. B → AB•,0 # complete จาก S(1,3)
6. A → B•B,1 # complete จาก S(1,6)
7. P → S•,0 # complete จาก S(0,1)
8. A → B•B,0 # complete จาก S(0,3)
9. B → •AB,3 # predict จาก 3,6,8.
10. B → •b,3 # predict จาก 3,6,8.
11. A → •BB,3 # predict จาก 9.
12. A → •a,3 # predict จาก 9.

S(2)

2. B → A•B,1 # complete จาก S(1,4)
5. A → •BB,2 # predict จาก 3.

S(1)

2. S → A•B,0 # complete จาก S(0,2)
3. B → A•B,0 # complete จาก S(0,5)
6. A → •BB,1 # predict จาก 4.

S(0)

1. P → •S,0 #suffix เริ่มต้น
3. A → •BB,0 #predict จาก 2.

B → AB | b

A → BB | a

121

# Earley Parser

S(4) : aabb•b

1. B → b•,3 # scan จาก S(3,10)
2. A → BB•,2 # complete จาก S(3,3)
3. A → BB•,1 # complete จาก S(3,6)
4. A → BB•,0 # complete จาก S(3,8)
5. A → B•B,3 # complete จาก S(3,11)
6. B → A•B,2 # complete จาก S(2,3)
7. B → A•B,1 # complete จาก S(1,4)
8. S → A•B,0 # complete จาก S(0,2)
9. B → A•B,0 # complete จาก S(0,5)
10. B → •AB,4 # predict จาก 5,6,7,8,9.
11. B → •b,4 # predict จาก 5,6,7,8,9.
12. A → •BB,4 # predict จาก 10
13. A → •a,4 # predict จาก 10

S(3)

3. A → B•B,2 # complete จาก S(2,5)
6. A → B•B,1 # complete จาก S(1,6)
8. A → B•B,0 # complete จาก S(0,3)
11. A → •BB,3 # predict จาก 9.

S(2)

3. B → •AB,2 # predict จาก 2

S(1)

4. B → •AB,1 # predict จาก 2,3

S(0)

2. S → •AB,0 #predict จาก 1.
5. B → •AB,0 #predict จาก 3.

122

# Earley Parser

S(5) : aabbb•

1. B → b•,4 # scan จาก S(4,11)
2. A → BB•,3 # complete จาก S(4,5)
3. B → AB•,2 # complete จาก S(4,6)
4. B → AB•,1 # complete จาก S(4,7)
5. S → AB•,0 # complete จาก S(4,8)
6. B → AB•,0 # complete จาก S(4,9)
7. A → B•B,4 # complete จาก S(4,12)
8. P → S•,0 # complete จาก S(0,1)

S(4)

5. A → B•B,3 # complete จาก S(3,11)
6. B → A•B,2 # complete จาก S(2,3)
7. B → A•B,1 # complete จาก S(1,4)
8. S → A•B,0 # complete จาก S(0,2)
9. B → A•B,0 # complete จาก S(0,5)
12. A → •BB,4 # predict จาก 10

S(0)

1. P → •S,0 #suffix เริ่มต้น

เนื่องจาก  $P \rightarrow S•,0$  ปรากฏอยู่ในสถานะสุดท้าย (อ่านสตริงหมดแล้ว) จึงสรุปได้ว่า  $G_1$  สามารถสร้างสตริง aabbb ได้

123