Tema 23

Parseo Top-down

Dr. Luis A. Pineda
ISBN: 970-32-2972-7

Proceso de parseo

- Del Latin: Partes del habla o categorías gramaticales
- Si G en una CFG sober Σ & $x \in \Sigma^*$, parsear x consiste en encontrar una derivación para x en G o determinar que ésta no existe (i.e. por lo que x no está en el lenguaje de G).

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Proceso de parseo

- Antecedentes: simulación de derivaciones en G por un a PDA:
 - Top-down (derivaciones más izquierdas)
 - Bottom-up (derivaciones más derechas)
- Pero, estos procesos son no determinísticos y no proveén de un algoritmo directamente!

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Algoritmos de parseo

- Algoritmo trivial: explorar todas las trayectorias (en el espacio no determinístico) en cierto orden (i.e. depth first o breath first) & ver si alguna trayectoria termina exitosamente
 - Muy costoso: búsqueda exponencial!

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Algoritmos de parseo

- Enfrentar el no-determinismo directamente:
 - Utilizar toda la información disponible en cada paso de la computación (local) y seleccionar la mejor alternativa (en algunos casos determinísticamente)
 - Capitalizar la forma de la gramática: Para seleccionar la siguiente movida considerar no sólo el símbolo hasta arriba del stack, sino también uno o más de los símbolos que siguen en la cinta!

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Top-down Lookahead Parser

- Movida 1:
 - Si el símbolo hasta arriba del stack es una variable en el lado izquierdo de una producción, reemplazar dicha variable por el lado derecho de la producción
 - Inspeccionar el símbolo actual (i.e. consumir) y escoger sólo producciones que tengan a dicho símbolo como el más izquierdo del lado derecho!
 - Usar no-determinismo sólo si no hay opción!

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Top-down *Lookahead* Parser

- Movida 2:
 - Si el símbolo de entrada corresponde con el símbolo hasta arriba del stack, consumir el símbolo y pop.

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación top-down

$L =$ El lenguaje de los paréntesis balanceados

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Cadena de entrada

Control de edos. finitos

Una gramática no-ambigua

La lógica de la máquina:
 Cancelar “[” en la cinta con “[” en el lado derecho de una producción; igual para “]”

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

AP no determinístico

Id	estado	entrad	top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TZ_0)
3	q_1	Λ	T	$(q_1, [T]T), (q_1, \Lambda)$
4	q_1	[	[	(q_1, Λ)
5	q_1	]	]	(q_1, Λ)
6	q_1	S	S	(q_1, Λ)
7	q_1	Λ	Z_0	(q_2, Z_0)
Otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación top-down

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Control de edos. finitos

Movida 0:

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación top-down

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Control de edos. finitos

Movida 1:

$S \Rightarrow T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación top-down

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Control de edos. finitos

La decisión es no-determinística cuando T está hasta arriba del stack: podemos escoger $[T]T$ o Λ

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación top-down

Claramente, escoger Λ no es una idea muy buena!

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Ver hacia adelante: *Lookahead*

Podemos ver el símbolo actual en la cinta (i.e. consumiendo el símbolo!)

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Una producción es útil si su símbolo más izquierdo del lado derecho es el mismo que el símbolo actual en la cinta de entrada

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

¡Ver hacia delante!

- Remover el no-determinismo inspeccionando un símbolo hacia adelante
- Sólo considerar producciones que tengan a dicho símbolo como el más izquierdo del lado derecho de la producción
- Diseñar una AP determinístico que corresponda con el AP no-determinístico original

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

AP lookahead determinístico

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	S	T	(q_5, Λ)
8	q_5	Λ	S	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	S	S	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Consume lookahead symbol

$T \rightarrow [T]T$

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	S	T	(q_5, Λ)
8	q_5	Λ	S	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	S	S	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Ver hacia adelante: *Lookahead*

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

Una producción es útil si su símbolo más izquierdo del lado derecho es el mismo que el símbolo actual en la cinta de entrada

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

A lookahead simulation

Ver hacia adelante!

Consumir el símbolo y push el lado derecho de la producción!

Control de edos. finitos

Stack: $[$, T , $]$, T , $\$$, Z_0

Derivation: $S \Rightarrow T\$ \Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

A lookahead simulation

... pero como ya consumimos al símbolo que vimos hacia adelante (i.e. "["), tenemos que eliminar el símbolo más izquierdo que está hasta arriba del stack (fue sólo un préstamo... no un regalo); para esto hay que ir al estado de mantenimiento q_1

Control de edos. finitos

Stack: $[$, T , $]$, T , $\$$, Z_0

Derivation: $S \Rightarrow T\$ \Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Consume lookahead symbol

Id	State	Input	Stack symbol	Move(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	S	T	(q_5, Λ)
8	q_5	Λ	$\$$	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	S	$\$$	(q_1, Λ)
12	q_1	Λ	Z_0	(q_5, Z_0)
Other combinations				non

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

Control de edos. finitos

Pop:

Stack: $[$, T , $]$, T , $\$$, Z_0

Derivation: $S \Rightarrow T\$ \Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

Control de edos. finitos

después del pop:

Stack: T , $]$, T , $\$$, Z_0

Derivation: $S \Rightarrow T\$ \Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

Control de edos. finitos

$\delta(q_1,], T) = ?$

En este caso no hay producción con T en el lado izquierdo y " $]$ " como símbolo más izquierdo del lado derecho!

Stack: T , $]$, T , $\$$, Z_0

Derivation: $S \Rightarrow T\$ \Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

$\delta(q_1,], T) = ?$

Quiere decir que el "]" actual cancela al último "[":
 $T \rightarrow \Lambda$

Embebido en:
 $T \rightarrow [T]T$

$S \Rightarrow T\$$
 $\Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

$\delta(q_1,], T) = ?$

Consumir "]" & pop "T"

$S \Rightarrow T\$$
 $\Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Pop "T]"

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	[	T	$(q_1, [T]T)$
4	q_1	Λ	[	(q_1, Λ)
5	q_1	]	T	(q_1, Λ)
6	q_1	Λ	]	(q_1, Λ)
7	q_1	S	T	(q_1, Λ)
8	q_1	Λ	S	(q_1, Λ)
9	q_1	[	[	(q_1, Λ)
10	q_1	]	]	(q_1, Λ)
11	q_1	S	S	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

$\delta(q_1,], T) = ?$

Consumir "]" & pop "T"

$S \Rightarrow T\$$
 $\Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

No hay entrada para $T \rightarrow \Lambda$

Id	estado	entrada	Top del stack	Movida(s)
3	q_1	[	T	$(q_1, [T]T)$
X	q_1	Λ	T	(q_1, Λ)

No hay entrada en la tabla para la regla: $T \rightarrow \Lambda$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Simulación lookahead

$S \rightarrow T\$$
 $T \rightarrow [T]T$
 $T \rightarrow \Lambda$

$\delta(q_1,], T) = (q_1, \Lambda)$

$S \Rightarrow T\$$
 $\Rightarrow [T]T\$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

lookahead el symbol \$

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	$\$$	T	(q_s, Λ)
8	q_s	Λ	$\$$	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	$\$$	$\$$	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

$T \rightarrow \Lambda$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Operaciones de pop

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	$\$$	T	(q_s, Λ)
8	q_s	Λ	$\$$	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	$\$$	$\$$	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Estado final

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, [T]T)$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	$\$$	T	(q_s, Λ)
8	q_s	Λ	$\$$	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	$\$$	$\$$	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

- ### El problema de la recursión izquierda
- Recursión izquierda:
 - Un problema con la simulación top-down lookahead:
 - Otra gramática no ambigua para L

$$S \rightarrow T\$$$

$$T \rightarrow T[T] | \Lambda$$
 - Una derivación más izquierda:

$$S \Rightarrow T\$ \Rightarrow T[T]\$ \Rightarrow T[T][T]\$ \Rightarrow T[T][T][T]\$ \dots$$

$$\dots \Rightarrow [][][]\$$$
 - Pero $T \rightarrow \Lambda$ realmente no existe en el AP determinístico!
- Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

AP no-determinístico

Id	estado	entrada	Top del stack	Movida(s)
1	q_0	Λ	Z_0	(q_1, SZ_0)
2	q_1	Λ	S	(q_1, TSZ_0)
3	q_1	$[$	T	$(q_1, T[T])$
4	q_1	Λ	$[$	(q_1, Λ)
5	q_1	$]$	T	(q_1, Λ)
6	q_1	Λ	$]$	(q_1, Λ)
7	q_1	S	T	(q_5, Λ)
8	q_5	Λ	S	(q_1, Λ)
9	q_1	$[$	$[$	(q_1, Λ)
10	q_1	$]$	$]$	(q_1, Λ)
11	q_1	S	S	(q_1, Λ)
12	q_1	Λ	Z_0	(q_2, Z_0)
otras combinaciones				ninguna

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

El problema de la recursión izquierda

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

El problema de la recursión izquierda

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Eliminando la recursión izquierda

- La solución:
 - Encontra una gramática equivalente sin recursión izq.
- Considerar las producciones-T (β no empieza con T)

$$T \rightarrow T\alpha \mid \beta$$
- Es posible generar $\beta\alpha^n$:

$$T \rightarrow T\alpha, T \rightarrow T\alpha\alpha, \dots, T \rightarrow T\alpha^n$$
 pero $T \rightarrow \beta$ & $T \rightarrow \beta\alpha^n$
- T genera la concatenación de β con la cerradura de α :

$$T \rightarrow \beta U \text{ \& } U \rightarrow \alpha^n$$

$$T \rightarrow \beta U \text{ \& } U \rightarrow \alpha U \mid \Lambda$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Eliminando la recursión izquierda

- La solución:
 - Encontra una gramática equivalente sin recursión izq.
- Considerar las producciones-T (β no empieza con T)

$$T \rightarrow T\alpha \mid \beta$$
- Reemplazar por:

$$T \rightarrow \beta U \text{ \& } U \rightarrow \alpha U \mid \Lambda$$
- Ejemplo:

$$T \rightarrow T[T] \mid \Lambda \quad (\alpha = [T], \beta = \Lambda)$$
- Reemplazar por:

$$T \rightarrow U \text{ \& } U \rightarrow [T]U \mid \Lambda$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Factorización

- Otra vez la gramática original:

$$S \rightarrow T$, \quad T \rightarrow [T]T \mid \Lambda$$
- Eliminar las producciones- Λ

$$S \rightarrow T$, \quad T \rightarrow [T]T \mid [T] \mid [T] \mid \Lambda$$
- Considerar el parseo por un lookahead AP:

$$S \rightarrow T$, \quad T \rightarrow [T]T \mid [T] \mid [T] \mid \Lambda$$
 - Cuando T está hasta arriba del stack hay 4 opciones
- Factorizar el primer símbolo del lado derecho:

$$S \rightarrow T$, \quad T \rightarrow [U, U \rightarrow [T]T \mid [T] \mid \Lambda$$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Factorización

- Los lados derechos que empiezan con T se pueden factorizar:

$$S \rightarrow TS, T \rightarrow [U, U \rightarrow T]T \mid [T \mid T]]$$

- Factorizar otra vez los lados derechos que empiezan igual:

$$\text{Sea } W \rightarrow T \mid \Lambda$$

$$\text{Entonces en } U \rightarrow T]W \mid]W$$

Consecuentemente:

$$S \rightarrow TS, T \rightarrow [U, U \rightarrow T]W \mid]W \ \& \ W \rightarrow T \mid \Lambda$$

- Eliminando a T ($T \rightarrow [U$):
 $S \rightarrow [US, U \rightarrow [U]W \mid]W \ \& \ W \rightarrow [U \mid \Lambda$
- El primer símbolo del lado derecho de todas las producciones con el mismo lado izquierdo es siempre diferente

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Gramáticas $LL(1)$

- Gramáticas $LL(1)$:
 - Sin recursión izquierda
 - Factorizadas: Para todas las producciones $\alpha \rightarrow a_i\beta$, donde a_i es diferentes para todas las producciones con el mismo lado izquierdo α

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Gramáticas $LL(1)$

- Se pueden parsear determinísticamente con un AP top-down viendo un símbolo hacia delante en la cinta de entrada
- Gramáticas $LL(k)$:
 - Parseo top-down determinístico
 - Viendo k símbolos hacia delante en la cinta de entrada

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

LLC no ambiguos

- LLC pueden parsearse determinísticamente viendo k hacia delante en la cinta de entrada

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7

Aumentando el espacio de las $LLC-D$

El parseo determinístico extiende la clase de los $LLC-D$

Dr. Luis A. Pineda, IIMAS, UNAM, 2005. ISBN: 970-32-2972-7