Parseo y Generación de Código

19 de septiembre de 2019

Análisis sintáctico ascendente

Licenciatura en Informática con Orientación en Desarrollo de Software
Universidad Nacional de Quilmes

Análisis sintáctico ascendente

Análisis sintáctico

Recordemos: dada una gramática $G = (N, \Sigma, P, S)$ y una cadena α, el problema de **análisis sintáctico** consiste en determinar si $\alpha \in L(G)$ y, en tal caso, dar una derivación $S \Rightarrow^\star \alpha$.

Análisis sintáctico descendente (repaso)

La clase pasada nos enfocamos en las técnicas de análisis sintáctico **descendente**.
El parser en cada paso tiene un árbol de derivación parcialmente construído, que se va completando desde la raíz hacia las hojas, consumiendo símbolos de la entrada y expandiendo producciones.

Análisis sintáctico descendente (repaso)

Por ejemplo, con la gramática $G = (\{E\}, \{\mathbf{n}, +\}, P, E)$:

$$\begin{array}{lcl} E & \rightarrow & T \mid T + E \\ T & \rightarrow & \mathbf{n} \end{array}$$

y la cadena de entrada $\mathbf{n} + \mathbf{n} + \mathbf{n}$ el proceso de análisis sintáctico descendente podría ser:

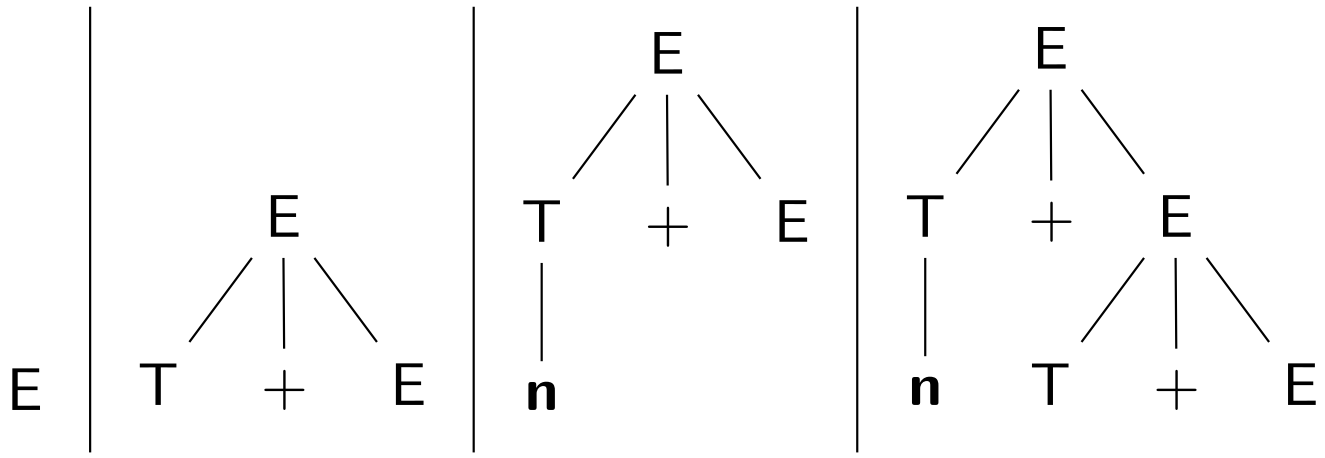

Análisis sintáctico descendente (repaso)

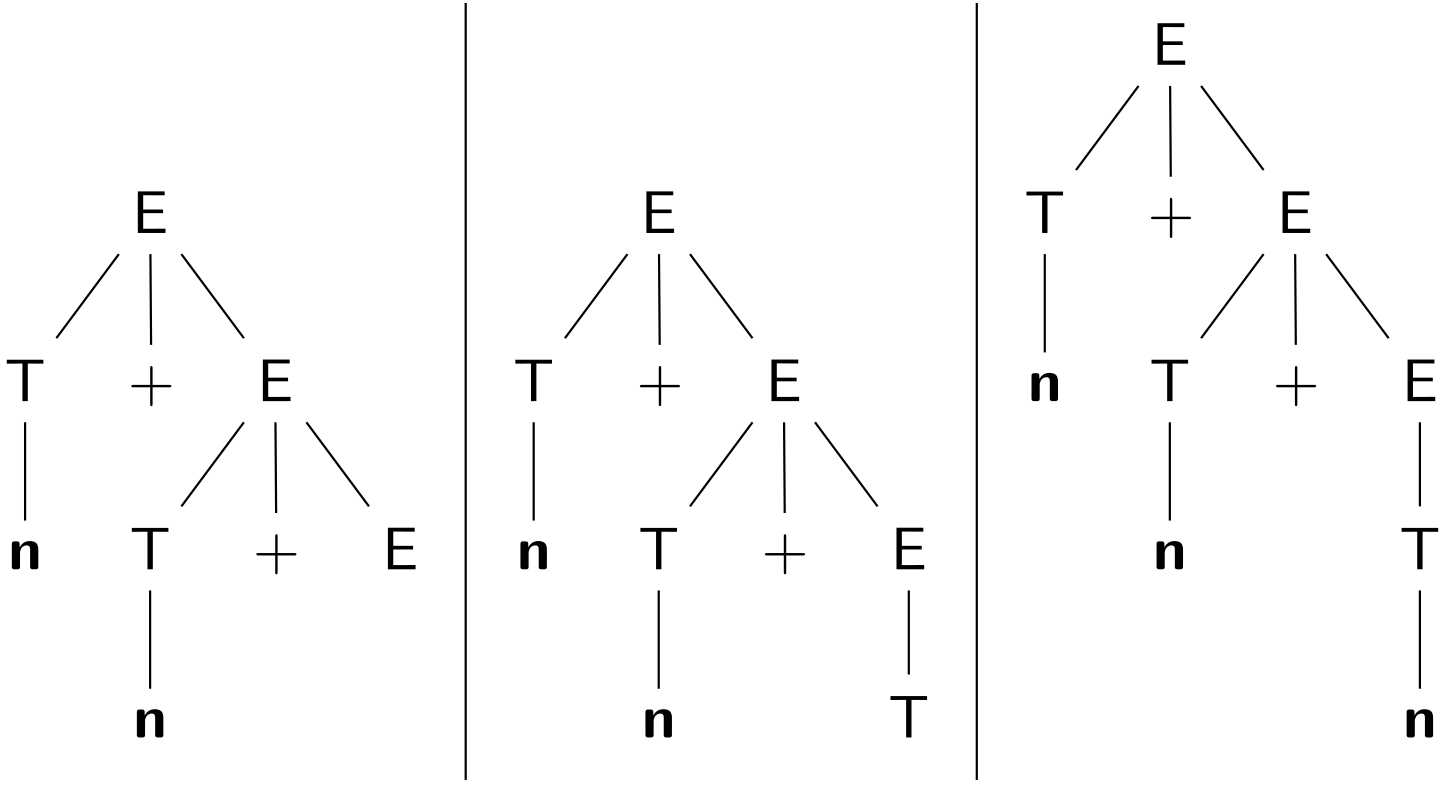

Observar que la derivación obtenida es una derivación **más a la izquierda**.

Análisis sintáctico ascendente

En esta clase nos enfocamos en las técnicas de análisis sintáctico **ascendente**.

El parser en cada paso tiene un árbol de derivación parcialmente construído, que se va completando desde las hojas hacia la raíz, consumiendo símbolos de la entrada y reduciendo producciones.

Análisis sintáctico ascendente

Por ejemplo, con la gramática $G' = (\{E\}, \{\mathbf{n}, +\}, P, E)$:

$$\begin{array}{lcl} E & \rightarrow & T \mid E + T \\ T & \rightarrow & \mathbf{n} \end{array}$$

y la cadena de entrada $\mathbf{n} + \mathbf{n} + \mathbf{n}$ el proceso de análisis sintáctico ascendente podría ser:

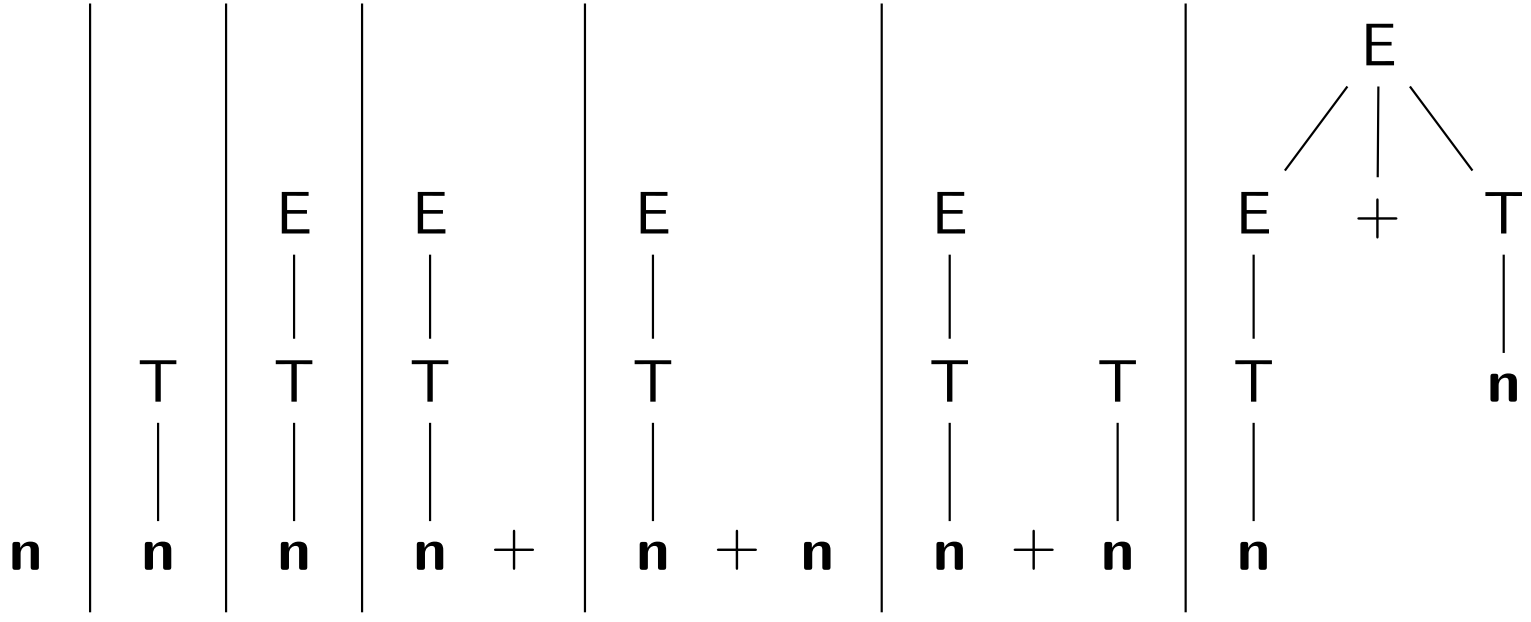

Análisis sintáctico ascendente

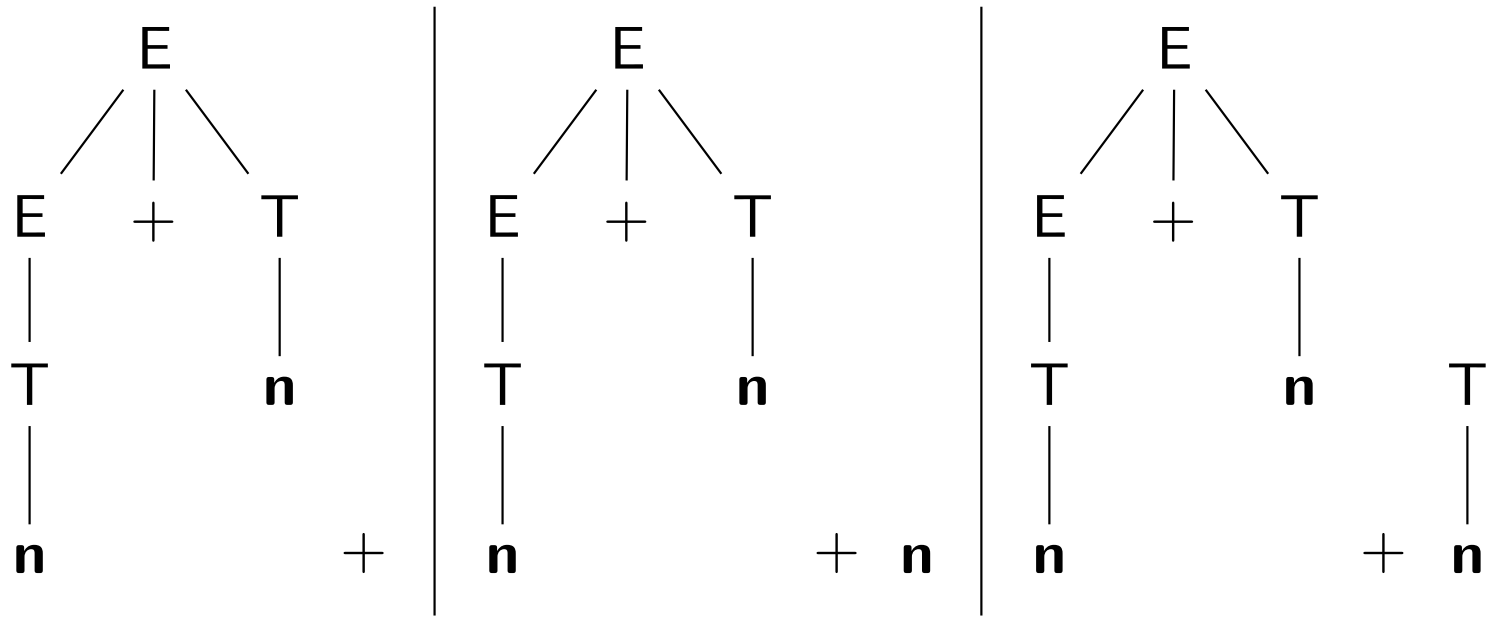

Análisis sintáctico ascendente

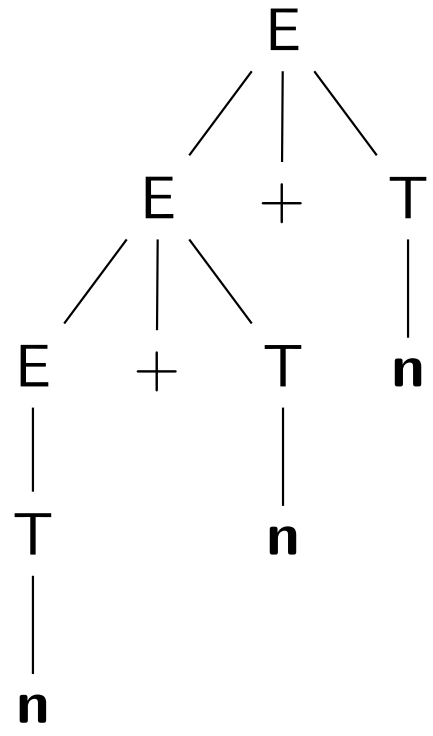

Observar que la derivación obtenida es una derivación **más a la derecha**.

Análisis sintáctico ascendente

En general en un momento dado del análisis sintáctico para la cadena $\alpha = a_1 \dots a_n$, ya se construyeron j subárboles del árbol de derivación. Es decir, se tiene una pila de j árboles:

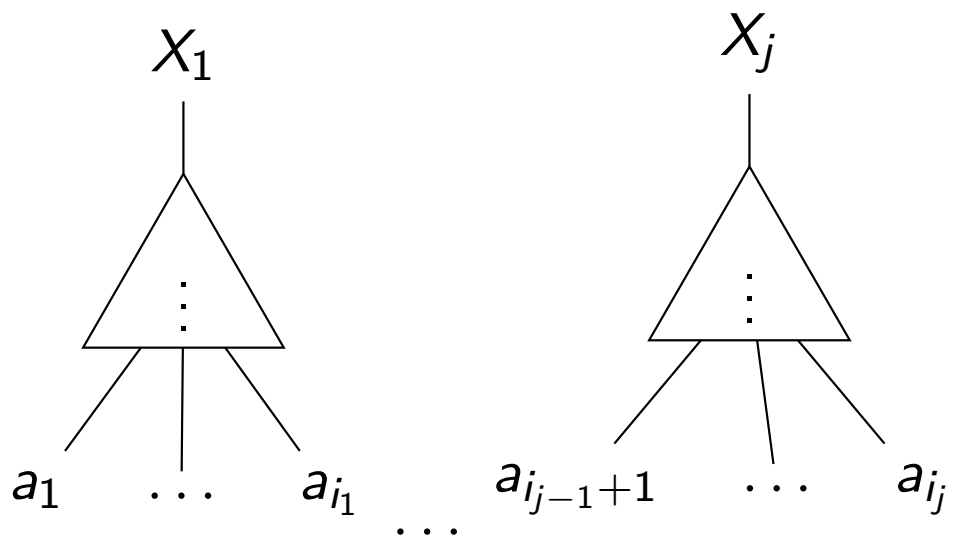

Hay tres acciones posibles:

Caso 1: si existe un k tal que los k símbolos $X_{j-k+1} \dots X_j$ en el tope de la pila corresponden al lado derecho de una producción $A \to X_{j-k+1} \dots X_j$, se aplica un paso **reduce**, creando un nuevo nodo A con dichos k árboles como hijos.

Análisis sintáctico ascendente

En general en un momento dado del análisis sintáctico para la cadena $\alpha = a_1 \dots a_n$, ya se construyeron j subárboles del árbol de derivación. Es decir, se tiene una pila de j árboles:

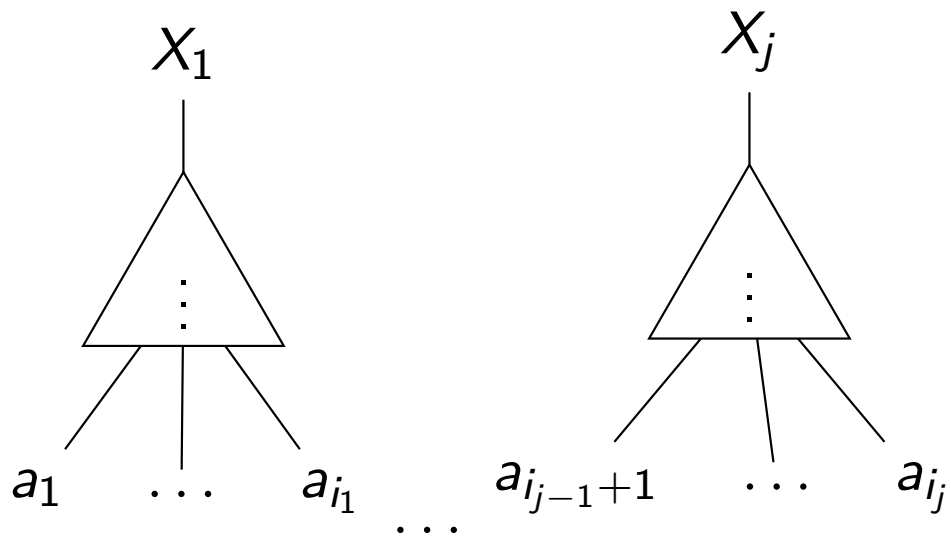

Hay tres acciones posibles:

Caso 2: si todavía hay símbolos de la entrada para consumir, se aplica un paso **shift**, incorporando el siguiente símbolo de la entrada a_{i_j+1} a la pila.

Análisis sintáctico ascendente

En general en un momento dado del análisis sintáctico para la cadena $\alpha = a_1 \ldots a_n$, ya se construyeron j subárboles del árbol de derivación. Es decir, se tiene una pila de j árboles:

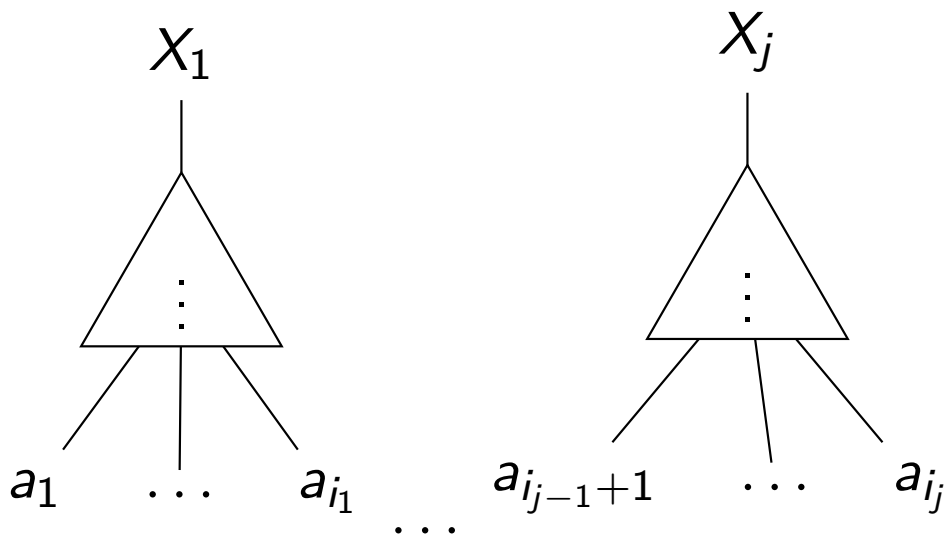

Hay tres acciones posibles:

Caso 3: en caso contrario, no hay símbolos para consumir y no es posible reducir la cadena en la pila. Si queda un único árbol de derivación con raíz S, es decir, $X_1 \ldots X_j = S$, la cadena se acepta. De lo contrario, se rechaza.

Análisis sintáctico ascendente con oráculo

El siguiente algoritmo genérico de análisis sintáctico ascendente asume que se dispone de un oráculo que siempre puede determinar si hay que hacer **shift** o **reduce**, y que en caso de **reduce** elige siempre la producción correcta.

Análisis sintáctico ascendente con oráculo

Entrada: Una gramática $G = (N, \Sigma, P, S)$,
una cadena α.
Salida: Un booleano indicando si $\alpha \in L(G)$ y en tal caso
una derivación más a la derecha de $S \Rightarrow^\star \alpha$.

pila := []
repeat forever
  if el oráculo elige una producción $A \to X_1 \dots X_k$ donde
    $X_1 \dots X_k$ son los k símbolos en el tope de la
    pila (X_k es el símbolo en el tope)
    Sacar k símbolos de *pila*.
    pila.push(A)
    Agregar la producción $A \to X_1 \dots X_k$ como primer
      paso de la derivación construida.
  elseif α no es vacía, $a\beta := \alpha$.
    pila.push(a)
    $\alpha := \beta$
  elseif *pila* = [S]
    return Éxito: $\alpha \in L(G)$ con la derivación construida.
  else
    return Falla: $\alpha \notin L(G)$.
  end

Análisis sintáctico ascendente con oráculo

Ejercicio. Usar el algoritmo de análisis sintáctico ascendente con la gramática $G = (\{E, T, F\}, \{+, *, \mathbf{n}, (,)\}, P, E)$:

$$\begin{array}{lcl} E & \rightarrow & T \mid E + T \\ T & \rightarrow & F \mid T * F \\ F & \rightarrow & \mathbf{n} \mid (E) \end{array}$$

para analizar la cadena $\mathbf{n} * \mathbf{n} + \mathbf{n}$.

Análisis sintáctico ascendente

- Notar que las acciones **reduce** por distintas producciones no son mutuamente excluyentes *a priori*. Por ejemplo, la cadena aa con la gramática (no ambigua) $G_1 = (\{S, A, B\}, \{a, b\}, P, S)$:

$$\begin{array}{lcl} S & \rightarrow & Aa \mid Bb \\ A & \rightarrow & a \\ B & \rightarrow & a \end{array}$$

- Notar que las acciones **shift** y **reduce** no son mutuamente excluyentes *a priori*. Por ejemplo, la cadena aab con la gramática (no ambigua) $G_2 = (\{S, A\}, \{a, b\}, P, S)$:

$$\begin{array}{lcl} S & \rightarrow & aAb \mid Ab \\ A & \rightarrow & a \end{array}$$

Análisis sintáctico ascendente

En el caso anterior de la gramática $G_2 = (\{S, A\}, \{a, b\}, P, S)$:

$$\begin{array}{lcl} S & \rightarrow & aAb \mid Ab \\ A & \rightarrow & a \end{array}$$

vemos que para la cadena aab no corresponde hacer un **reduce** $A \rightarrow a$ para la primera a.

Podemos refinar el criterio para aplicar una acción **reduce**.

Análisis sintáctico ascendente

- Si $S \Rightarrow^\star \alpha A \gamma \Rightarrow \alpha\beta\gamma$ es una derivación más a la derecha, se dice que la producción $A \to \beta$ junto con la posición $|\alpha|$ en la que se aplica es un **pivote** de $\alpha\beta\gamma$.
- Si el analizador sintáctico ascendente está en la siguiente situación:
  1. la pila es de la forma $\alpha\beta$,
  2. el fragmento de la entrada todavía no consumido es una cadena γ,

  el parser debe aplicar una acción **reduce** solamente si hay una producción $A \to \beta$ que es un pivote para $\alpha\beta\gamma$ en la posición $|\alpha|$.

Análisis sintáctico LR

- La clave de los parsers de la familia **LR** es que los pivotes se pueden identificar usando un autómata finito.
- Usando el autómata se puede decidir si corresponde ejecutar una acción **shift** o **reduce**.
- Veremos primero la técnica de análisis sintáctico LR(0), es decir, sin *lookahead*.

Análisis sintáctico LR(0)

- Si $G = (N, \Sigma, P, S)$ es una gramática, llamamos **ítem** a una producción que tiene un "puntito" en algún lado, es decir a un elemento de la forma $A \to \alpha \bullet \beta$ donde $(A \to \alpha\beta) \in P$ es una producción.
- Formalmente se puede modelar como un par $(A \to \alpha,\ i)$ donde $A \to \alpha$ es una producción. y $0 \leq i \leq |\alpha|$ es la posición del puntito.
- Para implementar el analizador sintáctico, un ítem se puede representar como un par de números (j, i) donde j identifica la producción (e i la posición del puntito).
- Por ejemplo, la producción $E \to T + E$ tiene cuatro ítems asociados:

$$E \to \bullet T + E$$

$$E \to T \bullet + E$$

$$E \to T + \bullet E$$

$$E \to T + E \bullet$$

Análisis sintáctico LR(0)

Clausura de un conjunto de ítems.

Si I es un conjunto de ítems, escribimos $\text{CLAUSURA}(I)$, y llamamos **clausura de** I, al conjunto de ítems tal que:

1. $I \subseteq \text{CLAUSURA}(I)$
2. Siempre que $\text{CLAUSURA}(I)$ incluye un ítem $A \to \alpha \bullet B\beta$, también incluye a todos los ítems de la forma $B \to \bullet\gamma$.
3. $\text{CLAUSURA}(I)$ es el conjunto de ítems más chico que verifica las condiciones 1. y 2.

Se puede calcular de manera sencilla siguiendo la definición:

Entrada: Una gramática $G = (N, \Sigma, P, S)$,
un conjunto de ítems I.
Salida: El conjunto de ítems CLAUSURA(I).

```
J := I
while hay cambios
    foreach ítem (A → α • Bβ) ∈ J
        J := J ∪ {(B → •γ) | (B → γ) ∈ P}
    end
end
return J
```

Análisis sintáctico LR(0)

Ejercicio. Calcular la clausura de $\{E' \to \bullet E\}$ en la gramática $G = (\{E', E, T\}, \{\mathbf{n}, +, (,), \$\}, P, S)$:

$$\begin{array}{lcl} E' & \to & E\$ \\ E & \to & T \mid E + T \\ T & \to & \mathbf{n} \mid (E) \end{array}$$

Análisis sintáctico LR(0)

Construcción de la tabla de análisis sintáctico LR(0).

- Una tabla de análisis sintáctico LR(0) es esencialmente un **autómata finito** determinístico en el alfabeto $N \cup \Sigma$ (símbolos terminales y no terminales).
- Sirve para detectar cuándo hay un pivote en la pila, es decir, funciona como un oráculo que indica si corresponde hacer *shift* o *reduce*.
- Los estados son **conjuntos de ítems**.
- Vamos a suponer que la gramática está extendida con un símbolo inicial S', un símbolo \$ y una producción $S' \to S\$$.
- La función de transición del autómata tradicionalmente se separa en dos partes:
  - A cada estado q y cada símbolo no terminal $A \in N$, la tabla asocia un estado GOTO$[q, A]$.
  - A cada estado q y cada símbolo terminal $a \in \Sigma$, la tabla asocia una acción ACTION$[q, x]$. Las acciones posibles son:
    - **Shift**(q) donde q es un estado.
    - **Reduce**$(A \to \alpha)$ donde $A \to \alpha$ es una producción.
    - **Accept**.

Análisis sintáctico LR(0)

Construcción de la tabla de análisis sintáctico LR(0).

Entrada: Una gramática $G = (N, \Sigma, P, S)$.
Salida: Una tabla de análisis sintáctico LR(0).

q_0 := CLAUSURA($\{S' \to \bullet S\$\}$)
Q := $\{q_0\}$
while hay un estado $q \in Q$ no visitado
    Marcar q como visitado.
    foreach símbolo $x \in N \cup \Sigma$
        q' := CLAUSURA($\{(A \to \alpha x \bullet \beta) \mid (A \to \alpha \bullet x\beta) \in q\}$)
        Q := $Q \cup \{q'\}$
        if x es un símbolo no terminal
            GOTO$[q, x]$:= q'
        else
            if $x = \$$ **and** $(S' \to S \bullet \$) \in q$
                ACTION$[q, x]$:= **Accept**
            if hay algún ítem $(A \to \alpha\bullet) \in q$
                ACTION$[q, x]$:= **Reduce**$(A \to \alpha)$
            if hay algún ítem $(A \to \alpha \bullet x\beta) \in q$
                ACTION$[q, x]$:= **Shift**(q')
        end
    end

Análisis sintáctico LR(0)

- Si a cada entrada de la tabla ACTION le corresponde a lo sumo una acción, se dice que la gramática es LR(0).
- Si alguna entrada de la tabla ACTION tiene dos o más acciones, la gramática no es LR(0) y se dice que hay un conflicto.

Análisis sintáctico LR(0)

Ejercicio. Construir la tabla de análisis sintáctico LR(0) para la gramática $G = (\{E', E, T\}, \{\mathbf{n}, +, (,), \$\}, P, S)$:

$$\begin{array}{lcl} E' & \to & E\$ \\ E & \to & T \mid E + T \\ T & \to & \mathbf{n} \mid (E) \end{array}$$

Análisis sintáctico LR(0)

La tabla de análisis sintáctico LR(0) puede tener conflictos **reduce/reduce**.

Esto se da cuando hay dos ítems de la forma $A \to \alpha\bullet$ en el mismo estado. Por ejemplo, para $G = (\{S', S, A\}, \{a, \$\}, P, S')$:

$$\begin{array}{lcl} S' & \to & S\$ \\ S & \to & a \mid A \\ A & \to & a \end{array}$$

Análisis sintáctico LR(0)

La tabla también puede tener conflictos **shift**/**reduce**.

Esto se da cuando hay un ítem de la forma $A \to \alpha\bullet$ y un ítem que no tiene esa forma en el mismo estado. Por ejemplo, para $G = (\{S', S, A\}, \{a, b, \$\}, P, S')$:

$$\begin{array}{lcl} S' & \to & S\$ \\ S & \to & A \mid Ab \\ A & \to & a \mid ab \end{array}$$

(El conflicto evidencia una ambigüedad en la gramática).

Análisis sintáctico LR(0)

Los conflictos generalmente corresponden a una ambigüedad en la gramática, pero pueden ser un artefacto de la construcción:
Por ejemplo, para $G = (\{S', S, A\}, \{a, b\}, P, S')$:

$$\begin{array}{lcl} S' & \rightarrow & S \\ S & \rightarrow & a \mid Ab \\ A & \rightarrow & a \end{array}$$

(Esta gramática no es ambigua pero tiene un conflicto).

Análisis sintáctico LR(0)

Algoritmo de análisis sintáctico LR.

Entrada: Una gramática $G = (N, \Sigma \cup \{\$\}, P, S')$ y una cadena α.
Salida: Un booleano indicando si $\alpha\$ \in L(G)$; en tal caso, una derivación más a la derecha para $S' \Rightarrow^{\star} \alpha\$$.

```
pila := [q0]  // pila de estados de la tabla LR(0)
a := primer símbolo de la entrada α$
repeat forever
  q := pila.tope()
  if ACTION[q, a] = Shift(q')
       pila.push(q')
       a := siguiente símbolo de la entrada
  elseif ACTION[q, a] = Reduce(A → β)
       Sacar |β| símbolos de pila.
       q' := pila.tope()
       pila.push(GOTO[q', A])
       Agregar la producción A → β como primer paso.
  elseif ACTION[q, a] = Accept
       return Éxito: con la derivación construida.
  else return Falla: error de sintaxis.
end
```

Análisis sintáctico LR(0)

Ejercicio. Analizar sintácticamente $n + (n + n)$ con la gramática $G = (\{E', E, T\}, \{\mathbf{n}, +, (,)\}, P, S)$:

$$E' \to E\$ \qquad E \to T \mid E + T \qquad T \to \mathbf{n} \mid (E)$$

usando la tabla de análisis sintáctico LR(0) ya construida:

	E	T	$\mathbf{n}$	$($	$)$	$+$	$\$$
1	2	4	**Shift**(9)	**Shift**(7)			
2						**Shift**(5)	**Accept**
3			$T \to (E)$	$T \to (E)$	$T \to (E)$	$T \to (E)$	$T \to (E)$
4			$E \to T$	$E \to T$	$E \to T$	$E \to T$	$E \to T$
5		6	**Shift**(9)	**Shift**(7)			
6			$E \to E + T$	$E \to E + T$	$E \to E + T$	$E \to E + T$	$E \to E + T$
7	10	8	**Shift**(9)	**Shift**(7)			
8			$E \to T$	$E \to T$	$E \to T$	$E \to T$	$E \to T$
9			$T \to \mathbf{n}$	$T \to \mathbf{n}$	$T \to \mathbf{n}$	$T \to \mathbf{n}$	$T \to \mathbf{n}$
10					**Shift**(3)	**Shift**(5)	

Análisis sintáctico SLR

- El algoritmo SLR es una ligera variante de LR(0).
- Las acciones **reduce** no ocupan toda la "fila" de la tabla SLR.
- Solamente se reduce por una producción $A \to \beta$ para los símbolos terminales que pueden aparecer a continuación de A.
- Más precisamente, se pone ACTION$[q, a] =$ **Reduce**$(A \to \beta)$ solamente cuando $a \in$ FOLLOW(A).
- La ventaja es que esto puede evitar conflictos **shift**/**reduce** y conflictos **reduce**/**reduce**.

Análisis sintáctico SLR

Ejercicio. Ya vimos que la tabla LR(0) para la gramática $G = (\{S', S, A\}, \{a, b, \$\}, P, S')$:

$$\begin{array}{lcl} S' & \to & S\$ \\ S & \to & a \mid Ab \\ A & \to & a \end{array}$$

tenía un conflicto **reduce**/**reduce**.

Ver que la tabla SLR para G no tiene conflictos.

Análisis sintáctico SLR

Ejercicio. ¿Cómo se modificaría la tabla LR(0) para la gramática de expresiones estudiada hace algunas diapositivas en el caso SLR?

Análisis sintáctico SLR

Las gramáticas SLR no son ambiguas.

Pero hay gramáticas no ambiguas que no son SLR. Por ejemplo, considerar $G = (\{S, L, R\}, \{\mathbf{id}, =, *\}, P, S)$:

$$\begin{array}{lcl} S & \rightarrow & L = R \mid R \\ L & \rightarrow & *R \mid \mathbf{id} \\ R & \rightarrow & L \end{array}$$

- La entrada **id** = **id** primero consume **id** y lo reduce a L.
- Acá se alcanza un conflicto **shift**/**reduce**:
  - ¿Se debe consumir =?
  - ¿O se debe reducir $R \rightarrow L$?
  - Observar que el símbolo = está en FOLLOW(R) de modo que el conflicto se da incluso en la gramática no es SLR.
  - Por otro lado, observar que no tiene sentido reducir $R \rightarrow L$.

Análisis sintáctico LR(1) canónico

- Otro algoritmo de la familia de LR es el algoritmo **LR(1) canónico**.
- Usa un token de *lookahead*.
- La idea es refinar el autómata: si el siguiente símbolo de la entrada es a, sólo se debe reducir por una producción $A \to \beta$ cuando a podría venir a continuación de A.

Análisis sintáctico LR(1) canónico

- Un **ítem LR(1)** es un par $[A \to \alpha \bullet \beta,\ a]$ donde $A \to \alpha\beta$ es una producción y $a \in \Sigma \cup \{\$\}$ es un símbolo terminal o \$.
- Los estados de la tabla de análisis sintáctico LR(1) son ahora conjuntos de ítems LR(1).
- Nos limitaremos a presentar la construcción de la tabla LR(1). Las modificaciones clave son:
  - La definición de ítem.
  - La clausura de un conjunto de ítems.

Análisis sintáctico LR(1) canónico

Clausura de un conjunto de ítems LR(1).

El cálculo de la clausura se modifica como sigue:

Entrada: Una gramática $G = (N, \Sigma, P, S)$, un conjunto de ítems LR(1) I.
Salida: El conjunto CLAUSURA(I).

```
J := I
while hay cambios
    foreach ítem [A → α • Bβ, a] ∈ J
        foreach producción B → γ
            foreach símbolo terminal b ∈ FIRST(βa)
                J := J ∪ {[B → •γ, b]}
            end
        end
    end
end
return J
```

Análisis sintáctico LR(1) canónico

Ejercicio. Calcular la tabla de análisis sintáctico LR(1) canónico para la gramática $G = (\{S', S, A\}, \{a, b\}, P, S')$:

$$\begin{array}{lcl} S' & \to & S \\ S & \to & AA \\ A & \to & aA \mid b \end{array}$$

Analizar sintácticamente la cadena $aabab$.

Análisis sintáctico LALR(1)

- El algoritmo LR(1) canónico es muy poderoso[1], pero el tamaño de las tablas de análisis sintáctico puede ser exponencial.
- El núcleo de un conjunto de ítems es el subconjunto de los ítems que **no** son de la forma $[A \to \bullet\beta,\ a]$.
- La explosión del tamaño de las tablas se puede controlar unificando todos los estados que tienen el mismo núcleo.
- En este caso la tabla de análisis sintáctico se conoce como **LALR(1)**.
- Hay algoritmos para construir directamente la tabla LALR(1) sin pasar por medio de la tabla LR(1).

[1] La clase de gramáticas LR(1) incluye a las LR(k) y a las LL(k) para todo k.

Análisis sintáctico LALR(1)

Ejemplo. Unificar los estados que comparten el mismo núcleo y obtener la tabla de análisis sintáctico LALR(1) para la gramática $G = (\{S', S, A\}, \{a, b\}, P, S')$:

$$\begin{array}{lcl} S' & \to & S \\ S & \to & AA \\ A & \to & aA \mid b \end{array}$$