

# Analyse non canonique

2005/2006

## 1 Rappels

### 1.1 Analyse LR

#### Grammaires LR( $k$ )

La classe des grammaires LR( $k$ ) est la classe de grammaires la plus large analysable de gauche à droite avec un automate à pile déterministe.

*Exercice 1.1.* Montrer que la grammaire suivante n'est pas LR( $k$ ) pour aucune valeur de  $k$  :

$$S \rightarrow BC \mid AD, \quad A \rightarrow a, \quad B \rightarrow a, \quad C \rightarrow CA \mid A, \quad D \rightarrow aD \mid b.$$

## 2 Analyse non canonique

### 2.1 Principes

#### Au-delà de LR( $k$ )

- Ne plus utiliser un automate à pile déterministe, mais un automate à deux piles déterministe.
- L'entrée sert de seconde pile.
- Les réductions se font en plaçant le symbole réduit sur la pile d'entrée.
- Les symboles non terminaux peuvent être utilisés en fenêtre.
- Les réductions de syntagmes qui ne sont pas des poignées sont permises.

*Exemple 2.1.* L'analyse non canonique pour

$$S \rightarrow BC \mid AD, \quad A \rightarrow a, \quad B \rightarrow a, \quad C \rightarrow CA \mid A, \quad D \rightarrow aD \mid b$$

va permettre la réduction de  $b$  à  $D$  dans la forme sententielle  $a^n b$ .

#### Exemple d'analyse

*Exemple 2.2.* Soit la grammaire

$$S \rightarrow BC \mid AD, \quad A \rightarrow a, \quad B \rightarrow a, \quad C \rightarrow CA \mid A, \quad D \rightarrow aD \mid b.$$

L'analyse non canonique de la phrase  $aaa$  se fait par les étapes :

$$\begin{aligned}
 & \$[\varepsilon]||aaa\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][a]||aa\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][a][aa]||a\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][a][aa][aaa]||\$ \\
 \stackrel{A \rightarrow a}{=} & \$[\varepsilon][a][aa]||A\$ \\
 \stackrel{A \rightarrow a}{=} & \$[\varepsilon][a]||AA\$ \\
 \stackrel{B \rightarrow a}{=} & \$[\varepsilon]||BAAS\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][B]||AA\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][B][BA]||A\$ \\
 \stackrel{C \rightarrow A}{=} & \$[\varepsilon][B]||CAS\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][B][BC]||A\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][B][BC][BCA]||\$ \\
 \stackrel{C \rightarrow CA}{=} & \$[\varepsilon][B]||C\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][B][BC]||\$ \\
 \stackrel{S \rightarrow BC}{=} & \$[\varepsilon]||S\$ \\
 \stackrel{\text{shift}}{=} & \$[\varepsilon][S]||\$
 \end{aligned}$$

**Les méthodes d'analyse non canonique**

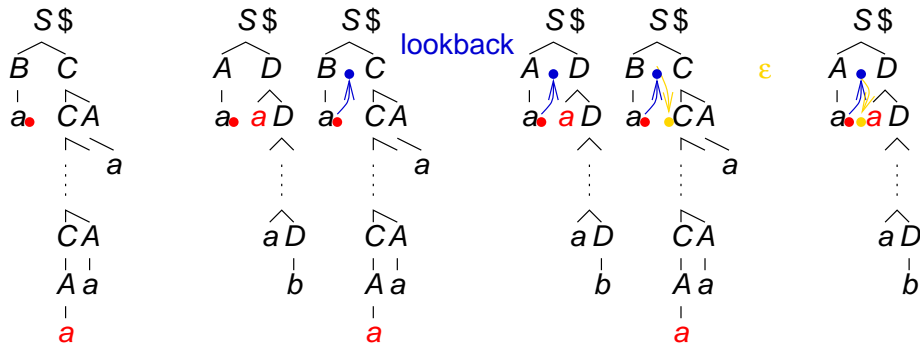
- LR( $k,t$ ) permet de réduire le  $t^{\text{e}}$  syntagme depuis l'extrémité gauche d'une forme sententielle [Knu65];
- *Total Precedence* étend l'analyse ascendante par précedence [Col70];
- BC( $m,n$ ) étend les méthodes à contexte borné [Wil72];
- LR( $k,\infty$ ) et FSPA( $k$ ) généralisent LR( $k,t$ ) [SW76];
- NSLR(1) étend l'analyse SLR(1) [Tai79];
- NDR est une extension de DR( $k$ ) [FFG04].

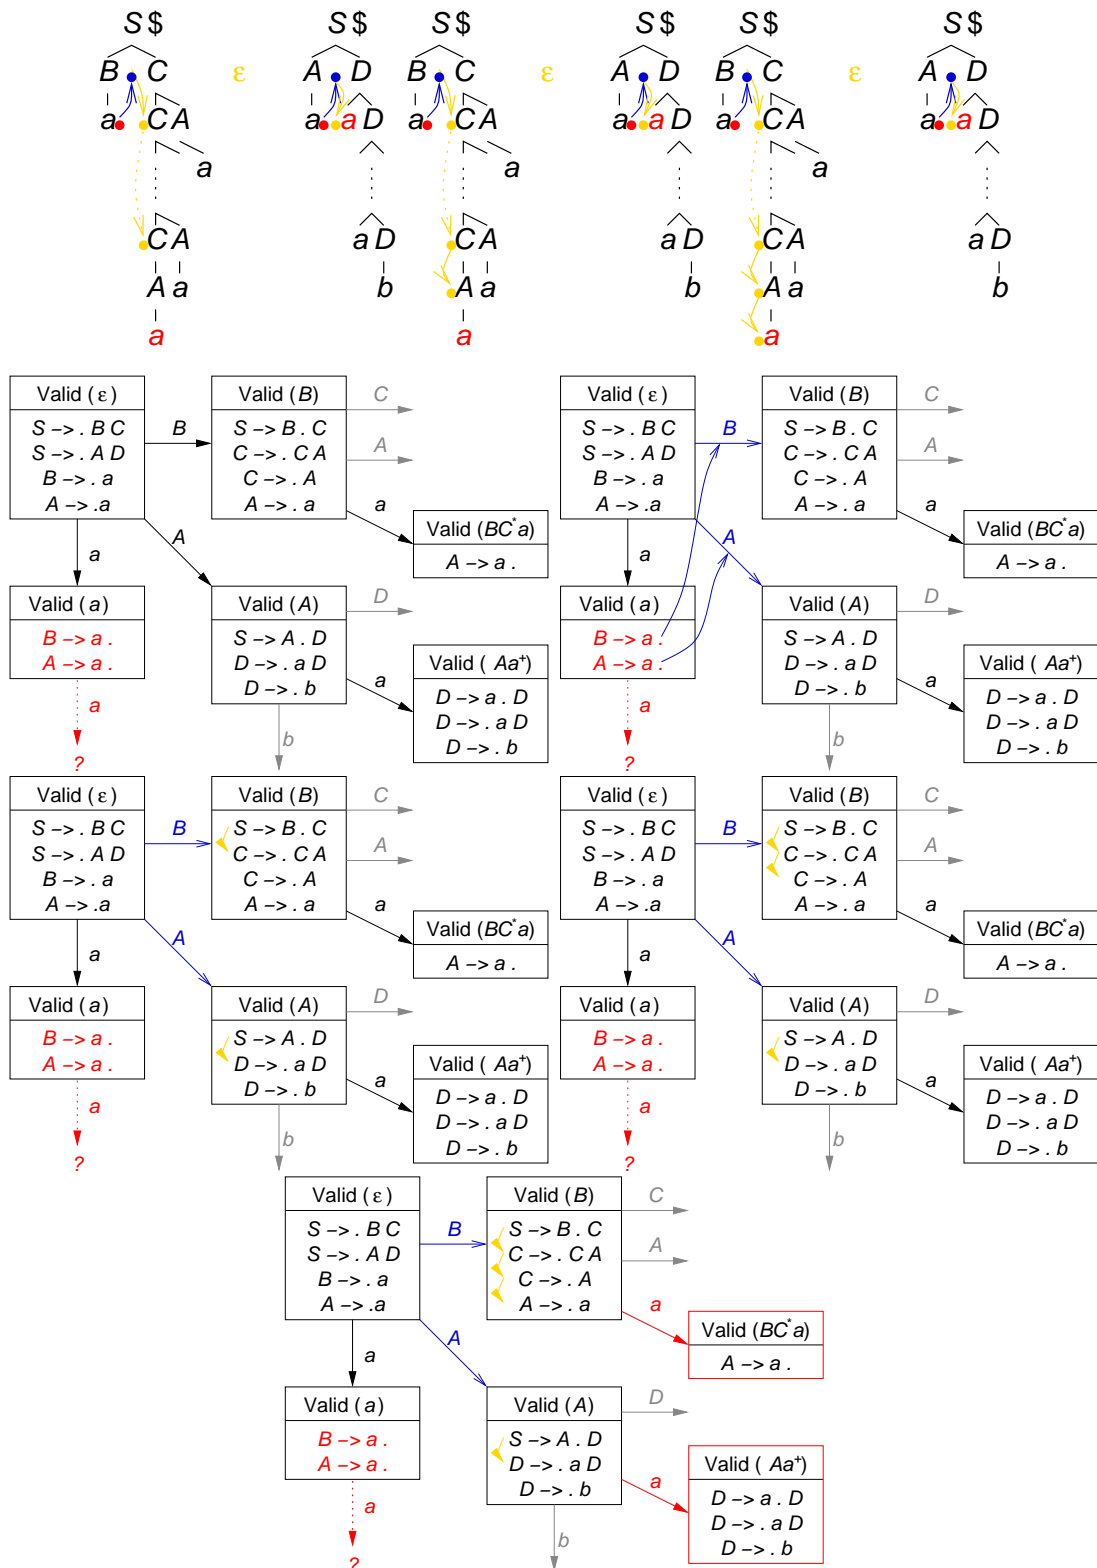
Nous allons présenter une analyse LALR(1) non canonique.

**2.2 Analyse NLALR(1)**

**Calcul des états non canoniques**

Comment passer des positions  $B \rightarrow a \cdot$  et  $A \rightarrow a \cdot$  de l'état  $[a]$  aux positions  $A \rightarrow a \cdot$  et  $D \rightarrow a \cdot D$  de l'état  $[[aa]]$  ?





L'état  $[aa]$  est l'union des états LR(0)  $[BC^*a]$  et  $[Aa^+]$ .

### Couvertures valides

On dit que les préfixes valides  $BC^*a$  et  $Aa^+$  couvrent le préfixe de forme sententielle  $aa$ , et effectivement  $Ba \Rightarrow^* aa$  et  $Aa \Rightarrow^* aa$ .

**Définition 2.3.** La chaîne  $\gamma$  est une *couverture valide* dans  $\mathcal{G}$  pour la chaîne  $\delta$  si et seulement si  $\gamma$  est un préfixe valide et  $\gamma \Rightarrow^* \delta$ .

On écrit  $\hat{\delta}$  pour dénoter une couverture de  $\delta$  et  $\text{Cover}(\delta)$  pour dénoter l'ensemble de toutes les couvertures valides pour  $\delta$ .

**Théorème 2.4.** Soit  $\alpha$  un syntagme tel que  $S' \Rightarrow^* \delta AX \omega \Rightarrow \delta \alpha X \omega$  avec  $q = [\hat{\delta}\alpha]$ , alors

$$\text{Cover}(\hat{\delta}AX) = \{\gamma CX \mid (q, A \rightarrow \alpha) \text{ lookback} \circ \text{includes}^* \circ \text{reads}^*([\gamma], C)\}.$$

### Fenêtres NLALR(1)

**Définition 2.5.** L'ensemble des *fenêtres réduites* pour une réduction par  $A \rightarrow \alpha$  dans l'état LR(0)  $q$  est défini par

$$\text{RLA}(q, A \rightarrow \alpha) = \{X \mid S' \xrightarrow{\text{im}}^* z A \gamma X \omega, \gamma \Rightarrow^* \varepsilon, X \Rightarrow^* ax, \text{ et } q = [\hat{z}\alpha]\}. \quad (1)$$

**Définition 2.6.** L'ensemble des *fenêtres dérivées* pour une réduction par  $A \rightarrow \alpha$  dans l'état LR(0)  $q$  est défini par

$$\text{DLA}(q, A \rightarrow \alpha) = \{X \mid S' \Rightarrow^* \delta AX \omega, X \Rightarrow^* ax, \text{ et } q = [\hat{\delta}\alpha]\}. \quad (2)$$

**Définition 2.7.** L'ensemble des *fenêtres en conflit* pour une réduction par  $A \rightarrow \alpha$  dans un ensemble d'états LR(0)  $s$  est défini par

$$\text{CLA}(s, A \rightarrow \alpha) = \{X \in \text{DLA}(q, A \rightarrow \alpha) \mid q \in s, ((q, X) \text{ ou } \exists p \in s, X \in \text{DLA}(p, B \rightarrow \beta)) \text{ et } X \notin \text{RLA}(q, A \rightarrow \alpha)\}.$$

L'ensemble de *fenêtres non canoniques* pour une réduction par  $A \rightarrow \alpha$  dans un ensemble d'états LR(0)  $s$  est défini par

$$\text{NLA}(s, A \rightarrow \alpha) = \left( \bigcup_{q \in s} \text{DLA}(q, A \rightarrow \alpha) \right) - \text{CLA}(s, A \rightarrow \alpha). \quad (3)$$

### Théorème 2.8.

$$\text{RLA}(q, A \rightarrow \alpha) = \{X \mid X \Rightarrow^* ax, \psi \Rightarrow^* \varepsilon, C \Rightarrow \rho B \cdot \psi X \sigma \in \text{Kernel}(\delta \rho B) \text{ et } (q, A \rightarrow \alpha) \text{ lookback} \circ \text{includes}^*([\delta \rho], B)\}.$$

Soit

$$\text{DR}([\delta], A) = \{X \mid ([\delta A], X) \text{ et } X \Rightarrow^* ax\},$$

alors

$$\text{DLA}(q, A \rightarrow \alpha) = \bigcup_{(q, A \rightarrow \alpha) \text{ lookback} \circ \text{includes}^* \circ \text{reads}^*(r, C)} \text{DR}(r, C).$$

### Exemple

*Exemple 2.9.* Les fenêtres non canoniques pour la réduction par  $A \rightarrow a$  dans l'état non canonique  $\llbracket aa \rrbracket = \{[BC^*a], [Aa^+]\}$  sont

$$\begin{aligned} \text{RLA}(\llbracket BC^*a \rrbracket, A \rightarrow a) &= \{A, \$\}, \\ \text{DLA}(\llbracket BC^*a \rrbracket, A \rightarrow a) &= \{A, a, \$\}, \\ \text{CLA}(\llbracket aa \rrbracket, A \rightarrow a) &= \{a\}, \text{ et} \\ \text{NLA}(\llbracket aa \rrbracket, A \rightarrow a) &= \{A, \$\}. \end{aligned}$$

### État non canonique NLALR(1)

**Définition 2.10.** L'état non canonique  $\llbracket \delta \rrbracket$  est l'ensemble d'états LR(0) défini par


$$\llbracket \varepsilon \rrbracket = \{[\varepsilon]\} \text{ et} \tag{4}$$

$$\begin{aligned} \llbracket \delta X \rrbracket = & \{[\widehat{\gamma A X}] \mid X \in \text{CLA}(\llbracket \delta \rrbracket, A \rightarrow \alpha) \text{ et } [\widehat{\gamma \alpha}] \in \llbracket \delta \rrbracket\} \\ & \cup \{[\varphi X] \mid [\varphi] \in \llbracket \delta \rrbracket\}. \end{aligned} \tag{5}$$

La *transition non canonique* depuis  $\llbracket \delta \rrbracket$  vers  $\llbracket \delta X \rrbracket$  sur le symbole  $X$ , dénotée par  $(\llbracket \delta \rrbracket, X)$ , existe si et seulement si  $\llbracket \delta X \rrbracket \neq \emptyset$ .

La réduction  $(\llbracket \delta \rrbracket, A \rightarrow \alpha)$  existe si et seulement si il existe une réduction  $(q, A \rightarrow \alpha)$  et si l'état LR(0)  $q$  est un élément de  $\llbracket \delta \rrbracket$ .

### Exemple



### Automate NLALR(1)

**Définition 2.11.** Un *automate NLALR(1)* pour la grammaire  $\mathcal{G}$  a pour configuration initiale  $\llbracket \varepsilon \rrbracket \| w \$$  avec  $w$  la chaîne d'entrée de  $\Sigma^*$ , pour configuration finale  $\llbracket \varepsilon \rrbracket \llbracket S \rrbracket \| \$$ , et des règles de réécriture de la forme

- *shift*  $X$  dans l'état  $\llbracket \delta \rrbracket$

$$\llbracket \delta \rrbracket \| X \xrightarrow{\text{shift}} \llbracket \delta \rrbracket \llbracket \delta X \rrbracket \|, \quad (6)$$

défini si il existe une transition  $(\llbracket \delta \rrbracket, X)$ , ou

- *reduce* par  $A \rightarrow X_1 \dots X_n$  dans l'état  $\llbracket \delta X_1 \dots X_n \rrbracket$  avec la fenêtre  $X$

$$\llbracket \delta X_1 \rrbracket \dots \llbracket \delta X_1 \dots X_n \rrbracket \| X \xrightarrow{A \rightarrow X_1 \dots X_n} \llbracket \delta X_1 \dots X_n \rrbracket \| AX, \quad (7)$$

défini si  $A \rightarrow X_1 \dots X_n$  est une réduction de  $\llbracket \delta X_1 \dots X_n \rrbracket$  et si la fenêtre  $X$  appartient à  $\text{NLA}(\llbracket \delta X_1 \dots X_n \rrbracket, A \rightarrow X_1 \dots X_n)$ .

## 3 Conclusion

### En bref

- Des méthodes d'analyse déterministes.
- Des méthodes plus puissantes que leurs pendants canoniques.
- Analyse en temps linéaire si la fenêtre a une longueur bornée.
- Peuvent être étendues pour utiliser une fenêtre de longueur non bornée à la LRR!

## References

- [Col70] Alain Colmerauer. Total precedence relations. *Journal of the ACM*, 17(1):14–30, January 1970.
- [FFG04] Jacques Farré and José Fortes Gálvez. Bounded-connect noncanonical discriminating-reverse parsers. *Theoretical Computer Science*, 313(1):73–91, February 2004.
- [Knu65] Donald E. Knuth. On the translation of languages from left to right. *Information and Control*, 8:607–639, 1965.
- [SW76] Thomas G. Szymanski and John H. Williams. Noncanonical extensions of bottom-up parsing techniques. *SIAM Journal of Computing*, 5(2):231–250, June 1976.
- [Tai79] Kuo-Chung Tai. Noncanonical SLR(1) grammars. *ACM Transactions on Programming Languages and Systems (TOPLAS)*, 1(2):295–320, 1979.
- [Wil72] John H. Williams. Bounded context parsable grammars. Technical Report 72-127, Department of Computer Science, Cornell University, Ithaca, New York, April 1972.