



LYCÉE LECONTE DE LISLE

## **Théorème de Myhill-Nerode et applications**

Vincent Picard

# Résiduels

Soit  $\Sigma$  un alphabet,  $L$  un langage sur  $\Sigma$  et  $u$  un mot sur  $\Sigma$ , on appelle **quotient à gauche** de  $L$  par  $u$  le langage :

$$u^{-1}L = \{v \in \Sigma^* / uv \in L\}$$

- C'est une notation, l'inverse d'un mot n'existe pas
- On appelle aussi les quotients d'un langage les **résiduels** du langage
- Exemple :
  - ▶  $L_1 = \{babbbb, baba, ababa, b, bba, babb, ba\}$
  - ▶ alors  $(ba)^{-1}L_1 = \{bbbb, ba, bb, \varepsilon\}$

## Exemples de résiduels : exercice

- $a^{-1}(a^*) =$
- $a^{-1}(a^*b^*) =$
- $a^{-1}(b^*a^*) =$
- $(ba)^{-1}\{\text{mots qui commencent par baba}\} =$
- $a^{-1}\{u \mid |u|_a \text{ est pair}\} =$
- $a^{-1}(ab)^* =$
- $b^{-1}(ab)^* =$

## Exemples de résiduels : solutions

- $a^{-1}(a^*) = a^*$
- $a^{-1}(a^*b^*) = a^*b^*$
- $a^{-1}(b^*a^*) = a^*$
- $(ba)^{-1}\{\text{mots qui commencent par baba}\} = \{\text{mots qui commencent par ba}\}$
- $a^{-1}\{u \mid |u|_a \text{ est pair}\} = \{u \mid |u|_a \text{ est impair}\}$
- $a^{-1}(ab)^* = b(ab)^*$
- $b^{-1}(ab)^* = \emptyset$

# Une propriété utile pour calculer les résiduels

Soit  $L$  un langage sur l'alphabet  $\Sigma$ ,  $u$  et  $v$  deux mots sur  $\Sigma$  alors

$$(uv)^{-1}L = v^{-1}u^{-1}L$$

## Démonstration

Pour tout mot  $w$ , on a les équivalences :

$$\begin{aligned}w \in v^{-1}u^{-1}L &\Leftrightarrow vw \in u^{-1}L \\ &\Leftrightarrow uvw \in L \\ &\Leftrightarrow w \in (uv)^{-1}L\end{aligned}$$

- Exemple :  $(ab)^{-1}(ab)^* = b^{-1}a^{-1}(ab)^* = b^{-1}b(ab)^* = (ab)^*$

## Exercice

Soit  $\Sigma = \{a, b\}$ . En utilisant la propriété précédente, répondre aux problèmes suivants

- Soit  $L_1 = (ab)^*$ , combien  $L_1$  a-t-il de résiduels ?
- Soit  $L_2 = \{a^n b^n, n \in \mathbb{N}\}$ , combien  $L_2$  a-t-il de résiduels ?

## Exercice (solutions)

Soit  $\Sigma = \{a, b\}$ . En utilisant la propriété précédente, répondre aux problèmes suivants

■ Soit  $L_1 = (ab)^*$ , combien  $L_1$  a-t-il de résiduels ?

▶  $\varepsilon^{-1}L_1 = L_1$

▶  $b^{-1}L_1 = \emptyset$

▶  $a^{-1}L_1 = b(ab)^*$

▶  $a^{-1}\emptyset = b^{-1}\emptyset = \emptyset$

▶  $a^{-1}b(ab)^* = \emptyset$

▶  $b^{-1}b(ab)^* = (ab)^* = L_1$

▶ **Conclusion :** il y a un nombre fini de résiduels  $\emptyset, b(ab)^*$  et  $(ab)^* = L_1$ .

■ Soit  $L_2 = \{a^n b^n, n \in \mathbb{N}\}$ , combien  $L_2$  a-t-il de résiduels ?

▶  $\varepsilon^{-1}L_2 = L_2$

▶  $b^{-1}L_2 = \emptyset$

▶  $a^{-1}L_2 = \{a^n b^{n+1}, n \in \mathbb{N}\} = H_1$

▶  $a^{-1}H_1 = \{a^n b^{n+2}, n \in \mathbb{N}\} = H_2$

▶  $a^{-1}H_2 = \{a^n b^{n+3}, n \in \mathbb{N}\} = H_3$

▶ ...

▶  $(a^k)^{-1} = \{a^n b^{n+k}, n \in \mathbb{N}\}$

▶ **Conclusion :** il y a un nombre infini de résiduels

# Équivalence de Myhill-Nerode

Soit  $L$  un langage sur l'alphabet  $\Sigma$ ,  $u$  et  $v$  sont dit équivalents au sens de Myhill-Nerode lorsque  $u^{-1}L = v^{-1}L$ . On notera  $u \sim_L v$ .

$\sim_L$  est une relation d'équivalence sur  $\Sigma^*$ .

- Deux mots  $u$  et  $v$  sont équivalents lorsqu'ils conduisent au même résiduel par quotient à gauche.
- $u \sim_L v$  signifie qu'après avoir lu  $u$  on va reconnaître les mêmes mots que si on avait commencé par lire  $v$  à la place de  $u$ .
- Exemples
  - ▶ Pour  $L = a^*$ ,  $a^{k_1} \sim_L a^{k_2}$  pour tous  $k_1, k_2 \in \mathbb{N}$
  - ▶ Pour  $L = (ab)^*$ ,  $a^5b^3 \sim_L a^7b^2$  car après avoir lu  $a^5b^3$  ou  $a^7b^2$ , il faut finir par un mot de  $b^*$  pour être dans  $L$ .



# Théorème de Myhill-Nerode (1957)

Le langage  $L$  est **régulier** (ou **reconnaisable** par automate fini)

$\Leftrightarrow$

$L$  possède un nombre **fini** de résiduels

$\Leftrightarrow$

le nombre de classes d'équivalences de  $\sim_L$  est **fini**

- La seconde équivalence est évidente :
  - ▶ Il y a bijection entre les résiduels de  $L$  et les classes d'équivalence de  $\sim_L$ .
  - ▶  $\varphi : u^{-1}L \mapsto \text{Cl}(u)$
- Pour la première équivalence, on va donner une preuve constructive.

# Un langage régulier possède un nombre fini de résiduels

- Soit  $L$  un langage reconnu par un afd **complet**  $A = (Q, q_0, F, \delta)$ . Pour tout état  $q \in Q$  on note  $L_q$  le langage des mots reconnus à **partir de l'état**  $q$  :

$$L_q = \{v \in \Sigma^* / \delta^*(q, v) \in F\}$$

- Soit  $u$  un mot sur  $\Sigma$  alors

$$\begin{aligned} u^{-1}L &= \{v / uv \in L\} \\ &= \{v / \delta^*(q_0, uv) \in F\} \\ &= \{v / \delta^*(\delta^*(q_0, u), v) \in F\} \\ &= L_{\delta^*(q_0, u)} \end{aligned}$$

- Ainsi, un résiduel de  $L$  est nécessairement l'un des langages  $L_q$  avec  $q \in Q$ , et comme l'ensemble des états de l'automate est fini, il ne peut y avoir qu'un nombre fini de résiduels.

# Si un langage possède un nombre fini de résiduels alors il est régulier

- Notons  $R$  l'ensemble fini des résiduels d'un langage  $L$ . On construit l'afd suivant :  $A = (R, q_0, F, \delta)$  avec
  - ▶ Les états sont les résiduels  $R$
  - ▶ L'état initial est le résiduel  $\varepsilon^{-1}L = L$
  - ▶ Les états finaux sont les résiduels qui contiennent le mot  $\varepsilon$  (Si on ajoute plus rien au mot déjà lu alors il est dans le langage  $L$ ).
  - ▶ Si  $\rho$  est un résiduel et  $a$  une lettre alors  $\delta(\rho, a) = a^{-1}\rho$ .
- Remarquons deux choses importantes :
  - ▶ L'automate est complet
  - ▶  $\delta$  est bien défini : car le résiduel d'un résiduel est toujours un résiduel

## L'automate des résiduels reconnaît bien $L$

Montrons que cet automate sert à calculer les quotients de  $L$  par tout mot  $u$  :  $\delta^*(q_0, u) = u^{-1}L$ . On le prouve par récurrence sur la longueur du mot  $u$  :


- **Initialisation** :  $\delta^*(q_0, \varepsilon) = q_0 = L = \varepsilon^{-1}L$
- **Hérédité** : on suppose la propriété vraie pour tout mot de longueur  $n$  et soit  $u = va$  un mot de longueur  $n + 1$ , alors

$$\begin{aligned}\delta^*(q_0, va) &= \delta(\delta^*(q_0, v), a) \\ &= \delta(v^{-1}L, a) \text{ par hypothèse de récurrence} \\ &= a^{-1}v^{-1}L \\ &= (va)^{-1}L\end{aligned}$$

- Et on en déduit :  $u \in L \Leftrightarrow \varepsilon \in u^{-1}L \Leftrightarrow \varepsilon \in \delta^*(q_0, u) \Leftrightarrow \delta^*(q_0, u) \in F$ .

## Exemple

- Construisons l'automate des résiduels du langage  $a(ab)^*$  :



- car  $a^{-1}(ab)^* = b(ab)^*$ ,  $b^{-1}b(ab)^* = (ab)^*$ , etc
- le résiduel  $(ab)^*$  est final car  $\varepsilon \in (ab)^*$

# Application : montrer qu'un langage n'est pas régulier

Sans le lemme de l'étoile...

- $L = \{a^n b^n, n \in \mathbb{N}\}$  n'est pas régulier.
- $L = \{a^p b^q / p < q\}$  n'est pas régulier.

## Application : Automate minimal

Si  $L$  est un langage à  $n \in \mathbb{N}^*$  résiduels alors il existe un plus petit automate fini déterministe complet à  $n$  états qui reconnaît  $L$ . Cet automate est appelé **automate minimal**.

### Démonstration

- Le sens réciproque de la preuve du théorème de Myhill-Nerode prouve l'existence d'un tel automate.
- Réciproquement, si  $A = (Q, q_0, F, \delta)$  est un afd complet qui reconnaît  $L$  alors, et qu'on considère deux mots  $u$  et  $v$  qui ne sont pas équivalents au sens de Myhill-Nerode :  $u^{-1}L \neq v^{-1}L$  alors nécessairement  $\delta^*(q_0, u) \neq \delta^*(q_0, v)$ . Ceci implique que  $Q$  possède au moins autant d'états que de classes d'équivalences de  $\sim_L$  c'est-à-dire  $n$ .
- On peut aussi montrer que si un tel automate possède exactement  $n$  états, alors les langages  $L_q$  correspondant aux mots acceptés depuis  $q$  sont les résiduels de  $L$  et que l'automate est isomorphe à l'automate des résiduels (unicité).

# Minimisation d'automates par fusion d'états

Soit  $A = (Q, q_0, F, \delta)$  un automate fini déterministe complet.


Soit  $q$  et  $q'$  deux états de l'automate, on dit que  $q$  et  $q'$  sont **équivalents au sens de Nerode** lorsque  $L_q = L_{q'}$ .

- Ainsi, ces états sont indistingables, quand on tombe sur  $q$  on va reconnaître par la suite exactement les mêmes mots que si on état tombé sur  $q'$ .
- Autrement dit, ces deux états correspondent à un même résiduel du langage reconnu.
- Pour minimiser un automate, il suffit de **fusionner** les états équivalents en 1 seul, jusqu'à aboutir sur l'automate minimal.
- Il existe des algorithmes permettant de détecter efficacement quels états sont équivalents ou pas dans un automate (algorithme par raffinement de Moore) et donc de minimiser un automate donné.




# Exemple

On veut minimiser l'automate suivant :




## Exemple




- On remarque que  $L_{q_4} = L_{q_5} = \{a, b, c\}^*$ .

## Exemple




- On fusionne  $q_4$  et  $q_5$  :
  - ▶ On supprime  $q_5$  et ses transitions sortantes
  - ▶ Toutes les transitions qui menaient à  $q_5$  mènent désormais à  $q_4$

## Exemple




- On remarque que  $L_{q_2} = L_{q_3} = \{a, c\}^* bL_{q_4}$ .

## Exemple




- On fusionne  $q_2$  et  $q_3$  :
  - ▶ On supprime  $q_3$  et ses transitions sortantes
  - ▶ Toutes les transitions qui menaient à  $q_3$  mènent désormais à  $q_2$

## Exemple




- On remarque que  $L_{q_0} = L_{q_1} = \{a, b\}^* c L_{q_2}$ .

# Exemple



- On fusionne  $q_0$  et  $q_1$  :
  - ▶ On supprime  $q_1$  et ses transitions sortantes
  - ▶ Toutes les transitions qui menaient à  $q_1$  mènent désormais à  $q_0$

## Exemple



- La minimisation est terminée car les états sont maintenant 2 à 2 non équivalents ( $L_{q_0}, L_{q_2}, L_{q_4}$  sont distincts 2 à 2)
- L'automate obtenu est l'automate minimal qui reconnaît le langage initial dénoté par :  $(a|b)^* c(a|c)^* b(a|b|c)^*$