

# Théorème de Kleene

Quentin Fortier

September 28, 2024

# Théorème de Kleene

L'objectif de ce cours est de montrer :

## Théorème de Kleene

Soit  $L$  un langage. Alors :

$L$  est régulier



$L$  est reconnaissable

# Régulier $\implies$ reconnaissable

Preuve de « régulier  $\implies$  reconnaissable » avec l'**algorithme de Berry-Sethi** :

- 1 Une expression régulière  $e$  peut être linéarisée (chaque lettre n'est alors utilisée qu'une seule fois).

# Régulier $\implies$ reconnaissable

Preuve de « régulier  $\implies$  reconnaissable » avec l'**algorithme de Berry-Sethi** :

- 1 Une expression régulière  $e$  peut être linéarisée (chaque lettre n'est alors utilisée qu'une seule fois).
- 2 Un langage linéaire est local.

# Régulier $\implies$ reconnaissable

Preuve de « régulier  $\implies$  reconnaissable » avec l'**algorithme de Berry-Sethi** :

- 1 Une expression régulière  $e$  peut être linéarisée (chaque lettre n'est alors utilisée qu'une seule fois).
- 2 Un langage linéaire est local.
- 3 Un langage local est reconnu par un automate local.

# Régulier $\implies$ reconnaissable

Preuve de « régulier  $\implies$  reconnaissable » avec l'**algorithme de Berry-Sethi** :

- 1 Une expression régulière  $e$  peut être linéarisée (chaque lettre n'est alors utilisée qu'une seule fois).
- 2 Un langage linéaire est local.
- 3 Un langage local est reconnu par un automate local.
- 4 Cet automate local peut être « délinéarisé » pour reconnaître  $L$ .

L'automate obtenu est appelé **automate de Glushkov**.

Régulier  $\implies$  reconnaissable : Langage linéaire

### Définition : Expression régulière linéaire

Une expression régulière est **linéaire** si chaque lettre y apparaît au plus une fois.

## Régulier $\implies$ reconnaissable : Langage linéaire

### Définition : Expression régulière linéaire

Une expression régulière est **linéaire** si chaque lettre  $y$  apparaît au plus une fois.

### Définition

Soit  $e$  une expression régulière sur un alphabet  $\Sigma$ .

Soit  $k$  le nombre de lettres (avec multiplicité) apparaissant dans  $e$ .

Soit  $\Sigma'$  un alphabet de taille  $k$ .

Linéariser  $e$  consiste à remplacer chaque occurrence de lettre apparaissant dans  $e$  par une lettre différente de  $\Sigma'$ .

# Régulier $\implies$ reconnaissable : Langage linéaire

## Définition : Expression régulière linéaire

Une expression régulière est **linéaire** si chaque lettre  $y$  apparaît au plus une fois.

## Définition

Soit  $e$  une expression régulière sur un alphabet  $\Sigma$ .

Soit  $k$  le nombre de lettres (avec multiplicité) apparaissant dans  $e$ .

Soit  $\Sigma'$  un alphabet de taille  $k$ .

Linéariser  $e$  consiste à remplacer chaque occurrence de lettre apparaissant dans  $e$  par une lettre différente de  $\Sigma'$ .

Exemple : soit  $e = \varepsilon | b(a|bb)^* b$ . En prenant  $\Sigma' = \{c_0, c_1, c_2, c_3, c_4\}$ , on peut linéariser  $e$  en  $e' = \varepsilon | c_0(c_1|c_2c_3)^* c_4$ .

## Définition

Soit  $L$  un langage. On définit :

- $P(L) = \{a \in \Sigma \mid a\Sigma^* \cap L \neq \emptyset\}$  (premières lettres des mots de  $L$ )
- $S(L) = \{a \in \Sigma \mid \Sigma^*a \cap L \neq \emptyset\}$  (dernières lettres des mots de  $L$ )
- $F(L) = \{u \in \Sigma^2 \mid \Sigma^*u\Sigma^* \cap L \neq \emptyset\}$  (facteurs de longueur 2 des mots de  $L$ )

## Définition

Soit  $L$  un langage. On définit :

- $P(L) = \{a \in \Sigma \mid a\Sigma^* \cap L \neq \emptyset\}$  (premières lettres des mots de  $L$ )
- $S(L) = \{a \in \Sigma \mid \Sigma^*a \cap L \neq \emptyset\}$  (dernières lettres des mots de  $L$ )
- $F(L) = \{u \in \Sigma^2 \mid \Sigma^*u\Sigma^* \cap L \neq \emptyset\}$  (facteurs de longueur 2 des mots de  $L$ )

## Question

Donner  $P(L)$ ,  $S(L)$ ,  $F(L)$  pour  $L = a^*b(ab)^*c$ .

# Régulier $\implies$ reconnaissable : Langage local

## Définition

Soit  $L$  un langage. On définit :

- $P(L) = \{a \in \Sigma \mid a\Sigma^* \cap L \neq \emptyset\}$  (premières lettres des mots de  $L$ )
- $S(L) = \{a \in \Sigma \mid \Sigma^*a \cap L \neq \emptyset\}$  (dernières lettres des mots de  $L$ )
- $F(L) = \{u \in \Sigma^2 \mid \Sigma^*u\Sigma^* \cap L \neq \emptyset\}$  (facteurs de longueur 2 des mots de  $L$ )

## Définition

Un langage  $L$  est **local** si, pour tout mot  $u = u_1u_2\dots u_n \neq \varepsilon$  :

$$u \in L \iff u_1 \in P(L) \wedge u_n \in S(L) \wedge \forall k, u_k u_{k+1} \in F(L)$$

Remarque :  $\implies$  est évident donc il suffit de prouver  $\impliedby$ .

# Régulier $\implies$ reconnaissable : Langage local

## Définition

Soit  $L$  un langage. On définit :

- $P(L) = \{a \in \Sigma \mid a\Sigma^* \cap L \neq \emptyset\}$  (premières lettres des mots de  $L$ )
- $S(L) = \{a \in \Sigma \mid \Sigma^*a \cap L \neq \emptyset\}$  (dernières lettres des mots de  $L$ )
- $F(L) = \{u \in \Sigma^2 \mid \Sigma^*u\Sigma^* \cap L \neq \emptyset\}$  (facteurs de longueur 2 des mots de  $L$ )

## Définition

Un langage  $L$  est **local** si, pour tout mot  $u = u_1u_2\dots u_n \neq \varepsilon$  :

$$u \in L \iff u_1 \in P(L) \wedge u_n \in S(L) \wedge \forall k, u_k u_{k+1} \in F(L)$$

Remarque :  $\implies$  est évident donc il suffit de prouver  $\impliedby$ .

## Exercice

Dire si les langages suivants sont locaux :  $L_1 = a^*$ ,  $L_2 = (ab)^*$ ,  
 $L_3 = a^*(ab)^*$ ,  $L_4 = a^*(ab)^*$ .

Régulier  $\implies$  reconnaissable : Linéaire  $\implies$  local

### Théorème

Soient  $L_1$  et  $L_2$  des langages locaux sur des alphabets disjoints  $\Sigma_1$  et  $\Sigma_2$ . Alors :

- $L_1 \cup L_2$  est local sur  $\Sigma_1 \cup \Sigma_2$
- $L_1 L_2$  est local sur  $\Sigma_1 \cup \Sigma_2$
- $L_1^*$  est local sur  $\Sigma_1$

On en déduit :

### Théorème

Tout langage linéaire est local.

# Régulier $\implies$ reconnaissable : Automate local

## Définition

Un automate déterministe  $(\Sigma, Q, q_0, F, E)$  est **local** si toutes les transitions étiquetées par une même lettre aboutissent au même état :

$$(q_1, a, q_2) \in E \wedge (q_3, a, q_4) \in E \implies q_2 = q_4$$

# Régulier $\implies$ reconnaissable : Automate local

## Définition

Un automate déterministe  $(\Sigma, Q, q_0, F, E)$  est **local** si toutes les transitions étiquetées par une même lettre aboutissent au même état :

$$(q_1, a, q_2) \in E \wedge (q_3, a, q_4) \in E \implies q_2 = q_4$$

## Théorème

Tout langage local  $L$  est reconnu par un automate local.

# Régulier $\implies$ reconnaissable : Automate local

## Définition

Un automate déterministe  $(\Sigma, Q, q_0, F, E)$  est **local** si toutes les transitions étiquetées par une même lettre aboutissent au même état :

$$(q_1, a, q_2) \in E \wedge (q_3, a, q_4) \in E \implies q_2 = q_4$$

## Théorème

Tout langage local  $L$  est reconnu par un automate local.

Preuve :

$L$  est reconnu par  $(\Sigma, Q, q_0, F, E)$  où :

- $Q = \Sigma \cup \{q_0\}$  : un état correspond à la dernière lettre lue
- $F = S(L)$  si  $\varepsilon \notin L$ , sinon  $F = S(L) \cup \{q_0\}$ .
- $E = \{(q_0, a, a) \mid a \in P(L)\} \cup \{(a, b, b) \mid ab \in F(L)\}$

# Régulier $\implies$ reconnaissable : Automate local

## Définition

Un automate déterministe  $(\Sigma, Q, q_0, F, E)$  est **local** si toutes les transitions étiquetées par une même lettre aboutissent au même état :

$$(q_1, a, q_2) \in E \wedge (q_3, a, q_4) \in E \implies q_2 = q_4$$

## Théorème

Tout langage local  $L$  est reconnu par un automate local.

Preuve :

$L$  est reconnu par  $(\Sigma, Q, q_0, F, E)$  où :

- $Q = \Sigma \cup \{q_0\}$  : un état correspond à la dernière lettre lue
- $F = S(L)$  si  $\varepsilon \notin L$ , sinon  $F = S(L) \cup \{q_0\}$ .
- $E = \{(q_0, a, a) \mid a \in P(L)\} \cup \{(a, b, b) \mid ab \in F(L)\}$

Exemple : construire un automate local reconnaissant  $e = a(a|b)^*$ .

## Régulier $\implies$ reconnaissable : Algorithme de Berry-Sethi

Soit  $e$  une expression régulière.

- 1 On linéarise  $e$  en  $e'$ , en remplaçant chaque lettre de  $e$  par une nouvelle lettre.
- 2 On construit un automate local  $A$  reconnaissant  $L(e')$ . Pour cela il faut calculer  $P(L(e'))$ ,  $S(L(e'))$ ,  $F(L(e'))$ .
- 3 On remplace chaque étiquette  $a$  de  $A$  en faisant l'opération inverse de 1. On obtient alors un automate (**automate de Glushkov**) reconnaissant  $L(e)$ .

# Régulier $\implies$ reconnaissable : Algorithme de Berry-Sethi

Soit  $e$  une expression régulière.

- 1 On linéarise  $e$  en  $e'$ , en remplaçant chaque lettre de  $e$  par une nouvelle lettre.
- 2 On construit un automate local  $A$  reconnaissant  $L(e')$ . Pour cela il faut calculer  $P(L(e'))$ ,  $S(L(e'))$ ,  $F(L(e'))$ .
- 3 On remplace chaque étiquette  $a$  de  $A$  en faisant l'opération inverse de 1. On obtient alors un automate (**automate de Glushkov**) reconnaissant  $L(e)$ .

On en déduit :

## Théorème

$L$  est un langage régulier  $\implies L$  est reconnaissable.

## Régulier $\implies$ reconnaissable : Algorithme de Berry-Sethi

Soit  $e$  une expression régulière.

- 1 On linéarise  $e$  en  $e'$ , en remplaçant chaque lettre de  $e$  par une nouvelle lettre.
- 2 On construit un automate local  $A$  reconnaissant  $L(e')$ . Pour cela il faut calculer  $P(L(e'))$ ,  $S(L(e'))$ ,  $F(L(e'))$ .
- 3 On remplace chaque étiquette  $a$  de  $A$  en faisant l'opération inverse de 1. On obtient alors un automate (**automate de Glushkov**) reconnaissant  $L(e)$ .

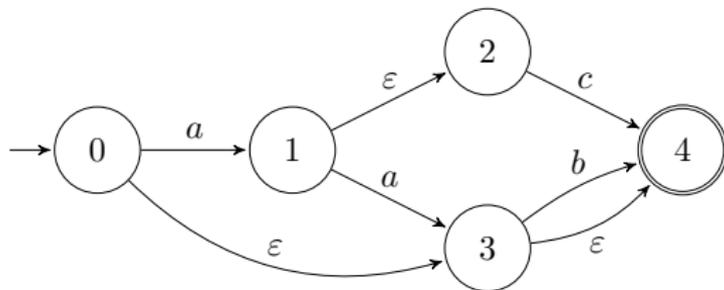
### Exercice

Construire l'automate de Glushkov reconnaissant  $L(a(a|b)^*)$ .

## $\varepsilon$ -transitions

On peut généraliser la notion d'automate en autorisant des  $\varepsilon$ -transitions (transition étiquetée par  $\varepsilon$ ).

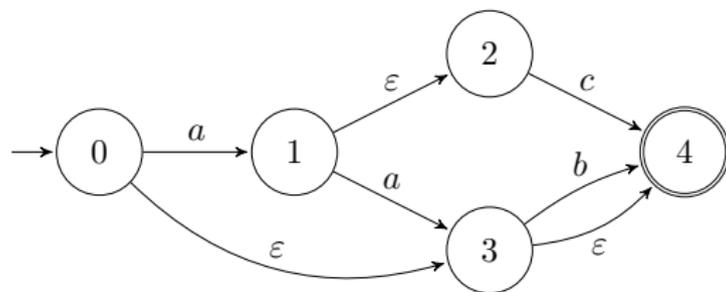
Exemple :



## $\varepsilon$ -transitions

On peut généraliser la notion d'automate en autorisant des  $\varepsilon$ -transitions (transition étiquetée par  $\varepsilon$ ).

Exemple :



Automate avec  $\varepsilon$ -transitions reconnaissant  
 $\{\varepsilon, b, ac, aa, aab\}$

### Théorème

Tout automate avec  $\varepsilon$ -transitions est équivalent à un automate sans  $\varepsilon$ -transition.

## Théorème

Tout automate avec  $\varepsilon$ -transitions est équivalent à un automate sans  $\varepsilon$ -transition.

Preuve :

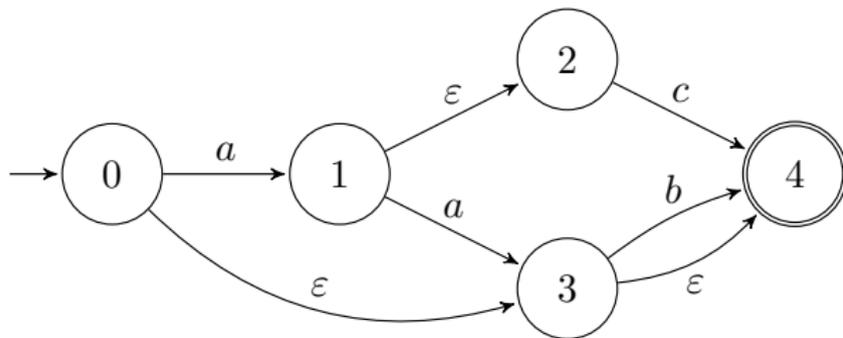
Soit  $A = (\Sigma, Q, I, F, \delta)$  un automate avec  $\varepsilon$ -transitions.

On définit  $A' = (\Sigma, Q, I', F, \delta')$  où :

- $I'$  est l'ensemble des états atteignables depuis un état de  $I$  en utilisant uniquement des  $\varepsilon$ -transitions.
- $\delta'(q, a)$  est l'ensemble des états  $q'$  tel qu'il existe un chemin de  $q$  à  $q'$  dans  $A$  étiqueté par un  $a$  et un nombre quelconque de  $\varepsilon$  (ce qui peut être trouvé par un parcours de graphe).

## Exercice

Donner un automate sans  $\epsilon$ -transition équivalent à l'automate suivant :



## Reconnaissable $\implies$ régulier : Élimination d'états

Soit  $L$  un langage reconnu par un automate  $A$ .

La **méthode d'élimination des états** permet de trouver une expression régulière  $e$  dont le langage est  $L$ .

## Reconnaissable $\implies$ régulier : Élimination d'états

On commence par se ramener à un automate plus simple :

### Lemme

Soit  $A$  un automate.

Il existe un automate  $A'$  équivalent à  $A$  avec :

- Un unique état initial sans transition entrante.
- Un unique état final sans transition sortante.

Preuve :

## Reconnaissable $\implies$ régulier : Élimination d'états

On commence par se ramener à un automate plus simple :

### Lemme

Soit  $A$  un automate.

Il existe un automate  $A'$  équivalent à  $A$  avec :

- Un unique état initial sans transition entrante.
- Un unique état final sans transition sortante.

Preuve : On ajoute un état initial  $q_i$  et un état final  $q_f$  et on ajoute des transitions  $\varepsilon$  depuis  $q_i$  vers les états initiaux de  $A$  et depuis les états finaux de  $A$  vers  $q_f$ .

## Reconnaissable $\implies$ régulier : Élimination d'états

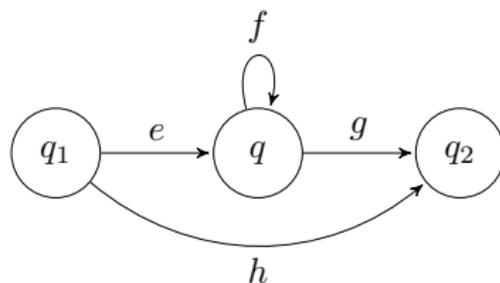
Soit  $A'$  un automate comme dans le lemme précédent.

Tant que  $A'$  possède au moins 3 états, on choisit un état  $q$  différent de  $q_i$  et  $q_f$

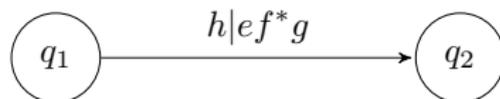
# Reconnaissable $\implies$ régulier : Élimination d'états

Soit  $A'$  un automate comme dans le lemme précédent.

Tant que  $A'$  possède au moins 3 états, on choisit un état  $q$  différent de  $q_i$  et  $q_f$ , on le supprime et on remplace chaque configuration :



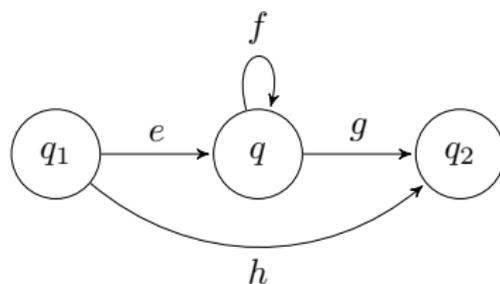
Par :



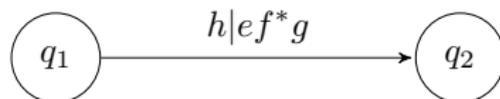
# Reconnaissable $\implies$ régulier : Élimination d'états

Soit  $A'$  un automate comme dans le lemme précédent.

Tant que  $A'$  possède au moins 3 états, on choisit un état  $q$  différent de  $q_i$  et  $q_f$ , on le supprime et on remplace chaque configuration :



Par :

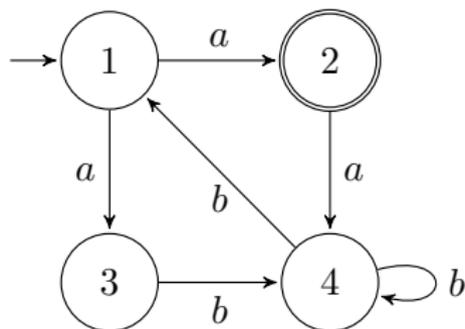


À la fin, l'étiquette de la transition restante donne une expression régulière de même langage que  $A'$ .

# Reconnaissable $\implies$ régulier : Élimination d'états

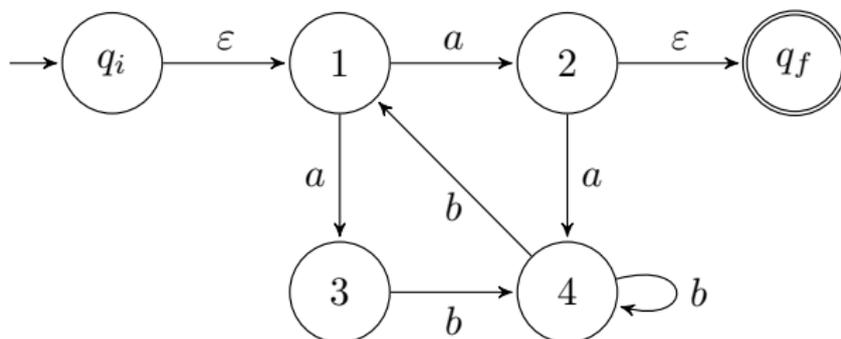
## Exercice

Donner une expression régulière de même langage que l'automate suivant, par la méthode d'élimination des états.



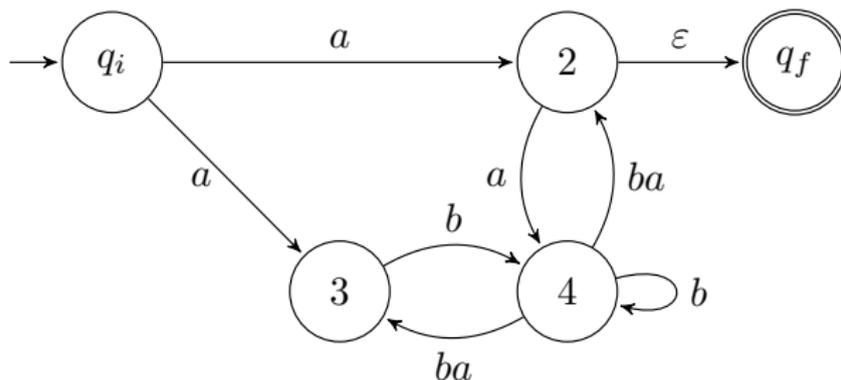
# Reconnaissable $\implies$ régulier : Élimination d'états

On commence par se ramener à un automate avec un état initial sans transition entrante et un état final sans transition sortante :



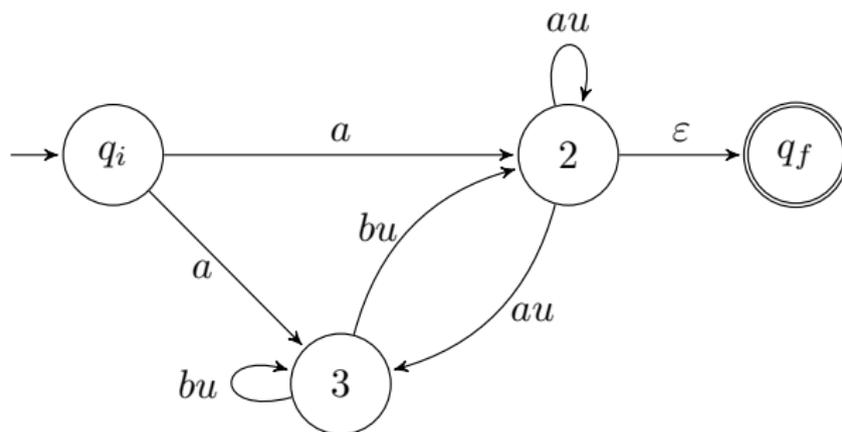
# Reconnaissable $\implies$ régulier : Élimination d'états

Suppression de l'état 1 :



# Reconnaissable $\implies$ régulier : Élimination d'états

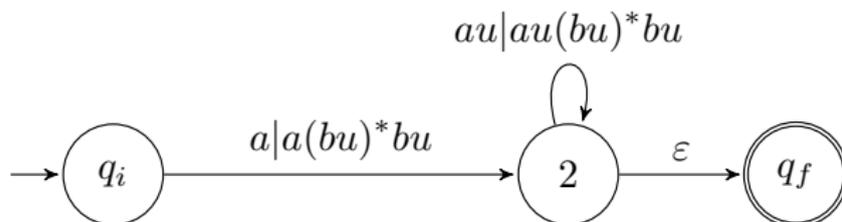
Suppression de l'état 4 :



Avec  $u = b^*ba$ .

# Reconnaissable $\implies$ régulier : Élimination d'états

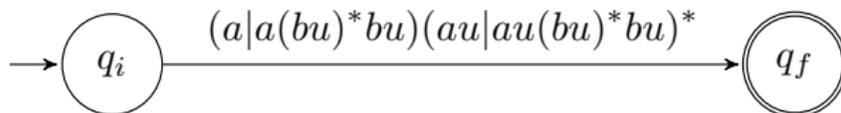
Suppression de l'état 3 :



Avec  $u = b^*ba$ .

# Reconnaissable $\implies$ régulier : Élimination d'états

Suppression de l'état 2 :



On obtient l'expression régulière  $a|a(bu)^*bu(au|au(bu)^*bu)$  (que l'on peut simplifier), où  $u = b^*ba$ .

# Reconnaissable $\implies$ régulier : Autre méthode : automate de Thompson

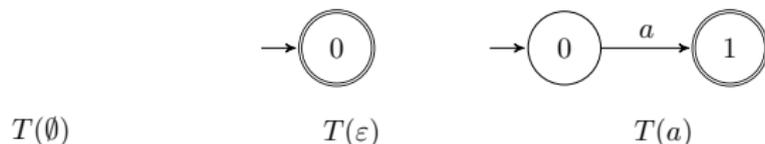
On construit récursivement l'**automate de Thompson**  $T(e)$  reconnaissant une expression régulière  $e$ .

- Cas de base :

# Reconnaissable $\implies$ régulier : Autre méthode : automate de Thompson

On construit récursivement l'**automate de Thompson**  $T(e)$  reconnaissant une expression régulière  $e$ .

- Cas de base :

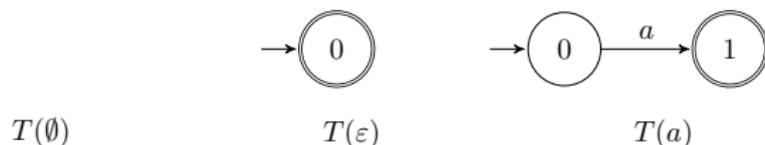


- $T(e_1 e_2)$  :

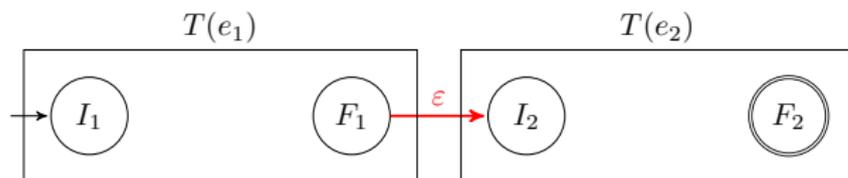
# Reconnaissable $\implies$ régulier : Autre méthode : automate de Thompson

On construit récursivement l'**automate de Thompson**  $T(e)$  reconnaissant une expression régulière  $e$ .

- Cas de base :



- $T(e_1 e_2)$  : on ajoute une  $\varepsilon$ -transition depuis chaque état final de  $T(e_1)$  vers chaque état initial de  $T(e_2)$ .

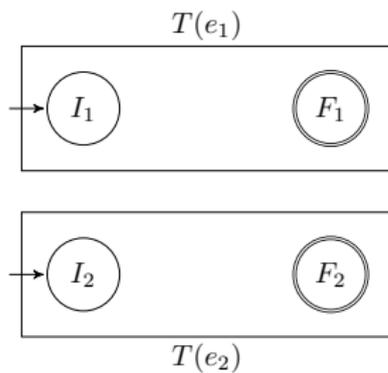


Reconnaissable  $\implies$  régulier : Autre méthode : automate de Thompson

- $T(e_1|e_2)$  :

# Reconnaissable $\implies$ régulier : Autre méthode : automate de Thompson

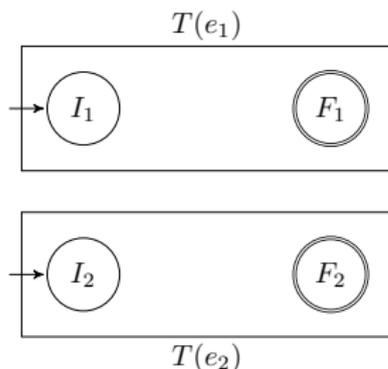
- $T(e_1|e_2)$  : on prend l'union des états initiaux et des états finaux.



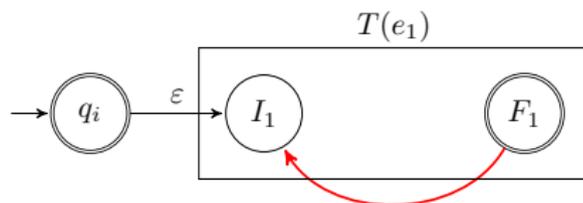
- $T(e_1^*)$  :

# Reconnaissable $\implies$ régulier : Autre méthode : automate de Thompson

- $T(e_1|e_2)$  : on prend l'union des états initiaux et des états finaux.



- $T(e_1^*)$  : on ajoute une  $\varepsilon$ -transition depuis chaque état final vers chaque état initial.



# Régulier $\iff$ reconnaissable

On a donc :

## Théorème de Kleene

Un langage est reconnaissable (par un automate) si et seulement s'il est régulier (décrit par une expression régulière).

# Régulier $\iff$ reconnaissable

On a donc :

## Théorème de Kleene

Un langage est reconnaissable (par un automate) si et seulement s'il est régulier (décrit par une expression régulière).

Tous les théorèmes sur les langages reconnaissables sont donc vrais aussi pour les langages réguliers :

## Théorème

Les langages réguliers sont stables par :

- Concaténation, union finie, étoile (par définition).
- Intersection finie, complémentaire, différence (d'après les résultats correspondants sur les automates).

# Régulier $\iff$ reconnaissable

On a donc :

## Théorème de Kleene

Un langage est reconnaissable (par un automate) si et seulement s'il est régulier (décrit par une expression régulière).

Tous les théorèmes sur les langages reconnaissables sont donc vrais aussi pour les langages réguliers :

## Théorème

Les langages réguliers sont stables par :

- Concaténation, union finie, étoile (par définition).
- Intersection finie, complémentaire, différence (d'après les résultats correspondants sur les automates).

## Exercice

Montrer que l'ensemble des mots sur  $\Sigma = \{a, b\}$  ne contenant pas de facteur  $ababb$  est régulier.