Langage naturel problèmes et solutions informatiques

Béatrice Daille

Université de Nantes

inspiré de J. Jurasky, L. Danlos et d'autres collègues

2001, L’Odyssée de l’espace

L’ordinateur HAL comprend l ’homme, dialogue avec lui dans sa langue, exécute ses commandes, et ressent des émotions.

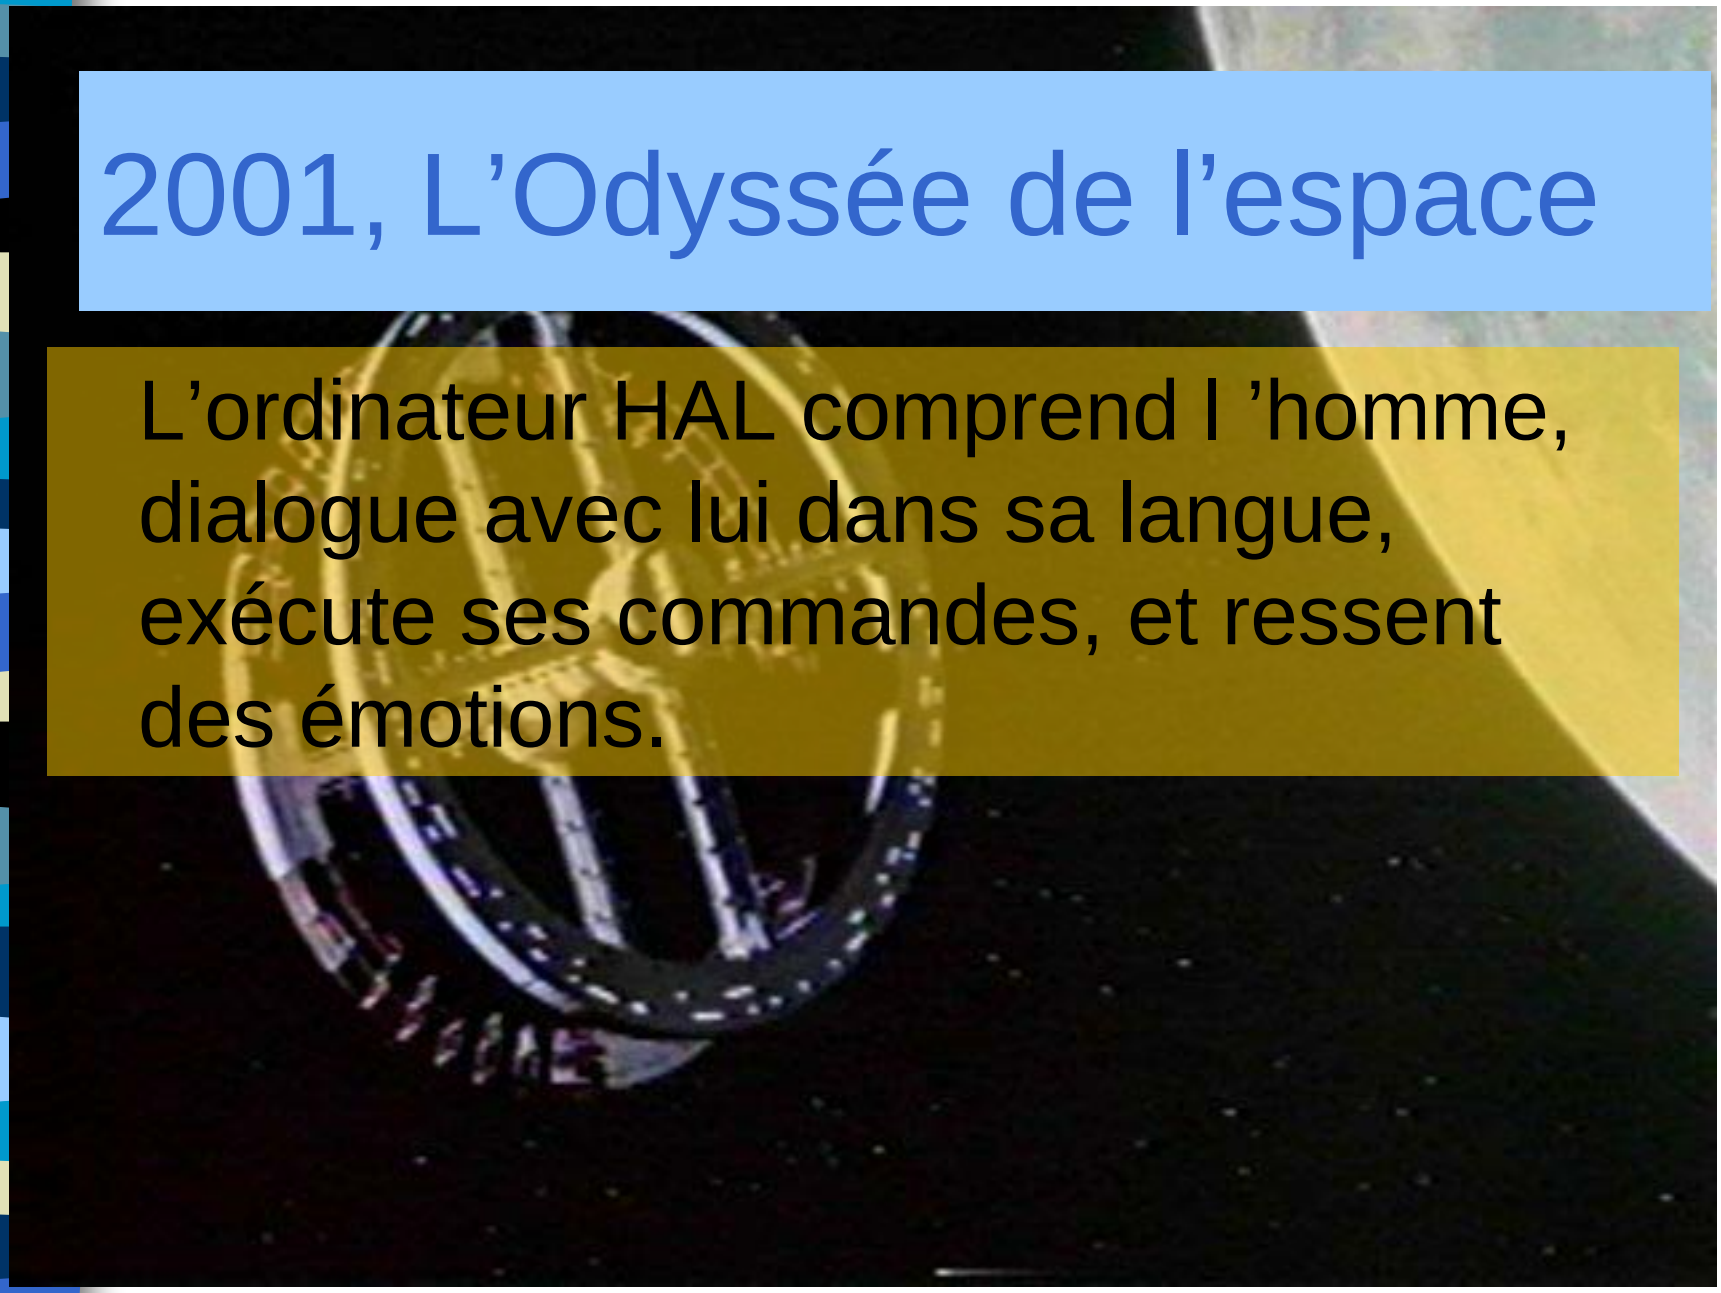

2001, L'Odyssée de l'espace

L'ordinateur HAL comprend l'homme, dialogue avec lui dans sa langue, exécute ses commandes et ressent des émotions.

A 12 ans de cette échéance

en est-on là ?

Applications du TALN

- Les voitures parlent
- Les machines à café comprennent votre commande
- Dictée automatique
- Correcteurs orthographiques et grammaticaux dans les traitements de textes
- Systèmes de traduction automatique
- Photocopieurs ou téléphones qui traduisent

Applications du TALN

- Moteurs de recherche du Web
- Assistante personnelle virtuelle
- Scanner (OCR)
- Saisie de textes sur des claviers de taille réduite
- Routage de documents
- Analyse des opinions

Plan de l'exposé

1. ***Les bases***
2. Application bluffante : ELIZA (1966)
3. ***Recherche de motifs***
   - ☐ ***Expressions rationnelles***
   - ☐ ***Automates à états finis***

Les bases

- Caractères et codes
- Chaînes de caractères et mots
- Phrases
- Textes, tris, loi de Zipf

Caractère (au sens informatique)

Pour l'ordinateur, chaque caractère correspond à un code, généralement un nombre entier, même les caractères invisibles.

Un code : une table de correspondance qui associe à une donnée numérique un symbole graphique (*glyphes*)

1	2	3	4	5	…	23	24	25	26
A	B	C	D	E	…	W	X	Y	Z

Critères des codes

Nom : un code est toujours nommé

Taille : Indication du nombre de bits nécessaires pour coder les symboles

Symboles (alphabet latin) :

- les 10 chiffres,
- les 26 lettres de l'alphabet
- les signes de ponctuation ou des opérateurs
- les *caractères de contrôle*

Traitement :

tri des caractères

Codes normalisés (1)

ASCII – Norme ISO 646 en 1963, puis en 1988

- 7 bits (128 caractères)
- universel : inclus dans les autres codes utilisés
- Codage :
  - 0 à 31 : caractères de contrôle
  - 32 à 47 : signes de ponctuation et opérateurs
  - 48 à 57 : chiffres 0 à 9
  - 65 à 90 : lettres majuscules (sans accent)
  - 97 à 122 : lettres minuscules (sans accent)
- Textes de la langue anglaise uniquement

Code ASCII – Table

	0	1	2	3	4	5	6	7
0	NUL	DLE	space	0	@	P	`	p
1	SOH	DC1 XON	!	1	A	Q	a	q
2	STX	DC2	"	2	B	R	b	r
3	ETX	DC3 XOFF	#	3	C	S	c	s
4	EOT	DC4	$	4	D	T	d	t
5	ENQ	NAK	%	5	E	U	e	u
6	ACK	SYN	&	6	F	V	f	v
7	BEL	ETB	'	7	G	W	g	w
8	BS	CAN	(	8	H	X	h	x
9	HT	EM	)	9	I	Y	i	y
A	LF	SUB	*	:	J	Z	j	z
B	VT	ESC	+	;	K	[	k	{
C	FF	FS	,	<	L	\	l	|
D	CR	GS	-	=	M	]	m	}
E	SO	RS	.	>	N	^	n	~
F	SI	US	/	?	O	_	o	del

Caractère : C

Nom : c majuscule

Décimal : 67

Hexadécimal : 43

Octal : 0103

Binaire : 010000011

Codes normalisés (2)

ISO Latin n (1987-)

- 8 bits (256 caractères)
- 128 premiers caractères : caractères ASCII
- 10 groupes : 128 autres caractères
- ISO-8859-1 ou ISO-LATIN-1 ou LATIN-1
- Langues de l'Europe de l'Ouest : allemand, anglais, danois, espagnol, féroïen, finnois, français, islandais, italien, néerlandais, norvégien, portugais, suédois.

Codes normalisés (3)

UNICODE 1993 http://www.unicode.org

- consortium Unicode (1989) : IS0 + constructeurs ordinateurs + … (Apple, IBM, Microsoft, etc.)
- 10 principes (universalité, efficacité, …)
- 16 bits (65 536 caractères)

ISO/IEC 10646

- 32 bits (4 milliards de caractères)
- UTF8 : Unicode sur 1 à 4 octets

UTF8

Implémentation de Unicode 5.0 (2006) : codage de taille variable

- 1 octet (8 bits) : caractères ASCII
- 2 octets (16 bits) : ISO-8859 (Latin1) + caractères alphabétiques
- 3 octets (24 bits) : Chinois, Japonais, Coréen
- 4 octets : tous les autres caractères

UTF8 – Exemple

Codage des caractères d'Unicode sous forme de séquences de un à quatre octets

Character	UTF-16	UTF-8	UCS-2
A	0041	41	0041
c	0063	63	0063
Ö	00F6	C3 B6	00F6
亜	4E9C	E4 BA 9C	4E9C
𝄞	D834 DD1E	F0 9D 84 9E	N/A

Commandes LINUX

- Détection

```
echo -n é | wc -c
file –i fichier.txt
utrac –p fichier.txt
```

- Conversion

```
iconv -f iso-8859-1 -t utf-8 entree.txt –o
  sortie.txt
iconv -f utf-8 -t iso-8859-1 –o entree.txt
  sortie.txt
```

Chaîne de caractères / Mot (au sens informatique)

- Une **chaîne de caractères** est une **séquence** de caractères
- Un **séparateur de mot** est un caractère particulier de l'alphabet qui permet de délimiter le mot
- Un **mot** est une séquence de lettres comprise entre 2 séparateurs de mots consécutifs

Phrase (au sens informatique)

- Un **délimiteur de phrase** est un caractère particulier de l'alphabet qui permet de délimiter la phrase
- Une **phrase** est une séquence de caractères comprise entre 2 séparateurs de phrases consécutifs

Texte et Tris

- Occurrence : l'apparition d'une chaîne de caractères dans un texte
- Fréquence : nombre d'occurrences
- Hapax : fréquence 1
- Tris
  - liste de fréquence : listes des occurrences accompagnées de leur fréquence
  - Autres listes : liste alphabétique, liste de première apparition

Loi de Zipf

Dans les années 30, un scientifique de l'université de Harvard, **G.K. Zipf**, a montré qu'en classant les mots d'un texte par fréquence décroissante, on observe que la fréquence d'utilisation d'un mot est inversement proportionnelle à son rang, r. Cette loi peut s'exprimer de la manière suivante :

Fréquence d'un mot de rang r = (Fréquence du mot de rang 1) / r

Loi de Zipf

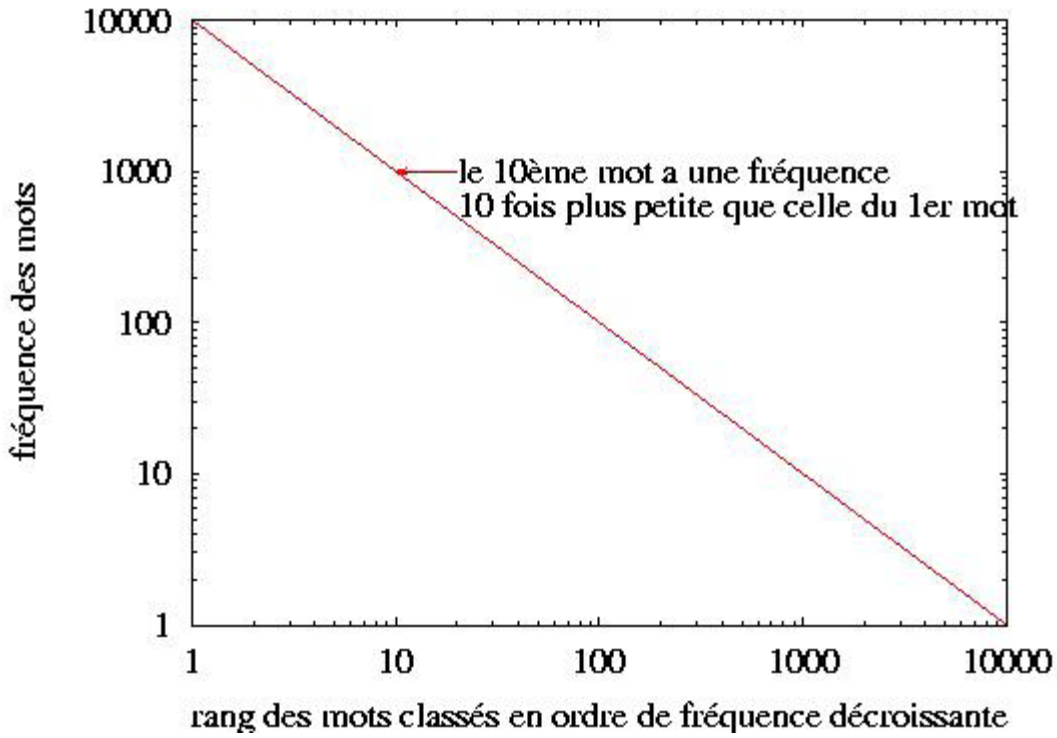
10000
1000
100
10
1
1
10
100
1000
10000
fréquence des mots
rang des mots classés en ordre de fréquence décroissante
le 10ème mot a une fréquence
10 fois plus petite que celle du 1er mot

Liste de fréquence des mots

Le Cid

Rang 1 429 *de*	2 264 *l'*	3 259 *?*
4 258 et	5 245 un	6 230 en
7 229 le	8 220 que	9 201 mon
10 198 est	11 191 Et	12 189 d'
13 187 je	14 177 la	15 167 il ….
16 155 vous	17 151 qu'	**40 67 Rodrigue**

Le journal Le Monde (10 ans)

Rang 1 16 702 498 *de*

Rang 2 9 239 401 *la*

Rang 3 7 048 266 *le*

Plan de l'exposé

1. ***Les bases***
2. Application bluffante : ELIZA (1966)
3. ***Recherche de motifs***
   - ☐ ***Expressions rationnelles***
   - ☐ ***Automates à états finis***

Eliza
(J. Weizenbaum, MIT, 1966)

Simulation de dialogue écrit entre
un psychothérapeute et un patient

Le psychothérapeute est un ordinateur

Eliza : exemples

- Bonjour, je suis votre psychothérapeute. Parlez moi de vos problèmes.
- Je suis très angoissé.
- Pourquoi dites-vous que vous êtes très angoissé ?
- C’est à cause de ma femme.
- Parlez-moi de votre famille.

Eliza : exemples

- J’adore mes enfants.
- J’aimerais que vous me parliez de vos relations avec vos enfants.
- Personne ne m’aime.
- Est-ce que ça vous ennuie que personne ne vous aime ?

Eliza : exemples

- Oui, je me sens seul.
- Votre vie sexuelle y est peut-être pour quelque chose. Continuez sans crainte.
- ...

Eliza : Analyse de l'exemple

- Bonjour, je suis votre psychothérapeute. Parlez moi de vos problèmes.
  - Texte figé qui commence tout dialogue
- Je suis très angoissé.
  - Réponse libre du patient
  - Stockée dans une variable R1
- Pourquoi dites-vous que vous êtes très angoissé ?
  - Pourquoi dites-vous que R1 ?
  - transformation : *je suis* → *vous êtes*

Eliza : Analyse de l'exemple

- C'est à cause de ma femme.
  - Réponse libre du patient qui contient le mot « femme »
- Parlez-moi de votre famille.
  - Ordre systématique du psy dès que la réponse précédente contient un mot de la liste : *femme, mari, mère, père,* etc.

Eliza : Analyse de l'exemple

- Oui, je me sens seul.
  - Réponse libre du patient qui ne contient rien de spécial
- Votre vie sexuelle y est peut-être pour quelque chose. Continuez sans crainte.
  - Réponse du psy quand il ne sait plus trop quoi dire

Bilan sur Eliza

- Application bluffante
- L'ordinateur ne comprend RIEN aux interventions du patient.
- Ses réponses : activation d'une des centaines ou milliers de réponses pré-enregistrées

  par la technique de recherche de motifs

Recherche de motifs

- Expressions régulières/rationnelles
- Automates à états finis

Expressions régulières

- Un langage formel pour décrire les chaînes de caractères
- Recherche/Remplacement de chaînes de caractères
- Notions
  - Caractère littéral/Méta-caractères
  - Classes de caractères
  - Quantificateurs
  - Ancres
  - Alternative (ou)

Expressions régulières

- Délimiteur d'expression régulière / /
- Syntaxe Perl (compatible JavaScript)
- Classe de caractères [ ]

Regexp	Correspondance	Formes
/[vV]alise/	Valise ou valise	« Valise »
/[abc]/	a ou b ou c	« valise »
/[1234567890]/	N'importe quel chiffre	« le 1er janvier »

Expressions régulières

- Classe de caractères

  expression d'un intervalle [-]

Regexp	Correspondance	Formes
/[a-z]/	une lettre minuscule	« la valise »
/[A-Z]/	une lettre majuscule	« la Valise »
/[0-9]/	un chiffre	« le 1er janvier »

Expressions régulières

- Négateur [^]

Regexp	Correspondance	Formes
/[^A-Z]/	pas une lettre majuscule	« La valise »
/[^Ss]/	ni S ni s	« Salut »
/[^\.]/	pas un point	« notre ami »
/[e^]/	soit e soit ^	« grand ^ »
/a^b/	la chaîne a^b	« ah a^b aah »

Expressions régulières

- Quantificateurs
  - ? 0 ou 1 fois
    - /voi?le/ ⇒ vole ou voile
  - * 0 ou n fois
    - /oo*h/ ⇒ oh ou ooh ou oooh ou ooooh …
  - + 1 ou n fois
    - /oo+h/ ⇒ ooh ou oooh ou ooooh

Expressions régulières

- Quantificateurs

{m,n} au minimum m occurrences et au maximum n occurrences

/me{2,3}uh/ ⇒ meeuh ou meeeuh

{m,} au minimum m occurrences

/me{2,}uh/ ⇒ meeuh ou meeeuh ou meeeeuh

{m} exactement m occurrences

/me{2}uh/ ⇒ meeuh

Expressions régulières

- N'importe quel caractère sauf fin de ligne .

  /b.l/ ⇒ bol ou bel ou b8l ou …

  /a.c./ ⇒ a1c1 ou abcd ou aacc ou …

- Ancres ^ $
  - /^[A-Z]/ ➔ "Ramallah, Palestine"
  - /^[^A-Z]/ ➔ "¿verdad?" "vraiment ?"
  - /\.$/ ➔ "La fin."
  - /.$/ ➔ ?
- alternative |
  - /vous|moi/ ➔ "c'est soit vous soit moi"

    ➔ "c'est soit moi soit vous"
  - /(lu|ma|me|je|ve|sa|di)/

Exemple

- Trouver toutes les occurrences du mot “les”
  - `/les/`

    `Pas de prise en compte des majuscules`
  - `/[lL]es/`

    `Trouve aussi lessive, faiblesse`
  - `/^[lL]es$/`
  - `/[^a-zA-Z][lL]es[^a-zA-Z]/`
  - `/(^|[^a-zA-Z])[lL]es[^a-zA-Z]/`

Erreurs

- 2 types d'erreurs
  - Chaînes trouvées que l'on n'aurait pas dû trouver (lessive, lest, faiblesse)
    - Faux positifs
  - Chaînes non trouvées que l'on aurait dû trouver
    - Faux négatifs

Réduire les erreurs

- Quelle que soit l'application, réduire son taux d'erreur prend en compte deux aspects antagonistes
  - Améliorer l'exactitude (réduire les faux positifs)
  - Améliorer la couverture (réduire les faux négatifs).

Remplacement et mémorisation

remplacement

```
s/feuile/feuille/
s/feuile/feuille/g
s/feuile/feuille/i
```

Remplacement de toutes les occurrences

Remplacement quelque soit la casse

Mémorisation à l'aide des variables : \1, \2, etc.

```
s/une petite (.+)/une
\1tte/
```

une petite fille → une fillette

Eliza : exemples

- Je suis très angoissé.
- Pourquoi dites-vous que vous êtes très angoissé ?
- C’est à cause de ma femme.
- Parlez-moi de votre famille.

Eliza : expressions régulières

Étape 1 : remplacer les pronoms à la 1ère personne du singulier par les pronoms à la 2ème personne du pluriel

```
s/\bje suis\b/vous êtes/g
s/\b ma\b /votre/g
```

Étape 2: utiliser des regexp pour générer les réponses

```
s/.* (vous êtes (très)? (angoissé|triste)) .*/Pourquoi
  dites-vous que \1/
```

Étape 3: utilisation de probabilités pour choisir parmi plusieurs remplacements possibles

Bilan sur les expressions régulières

- Les expressions régulières constituent un outil des plus utiles pour manipuler du texte
- Eliza : vous pouvez déjà faire beaucoup en n'utilisant que des expressions régulières

Automates à états finis

- Les expressions régulières sont une des manières d'exprimer un automate à états finis
- Les automates à états finis sont au cœur de nombreux algorithmes du traitement automatique du langage naturel

Automates à états finis

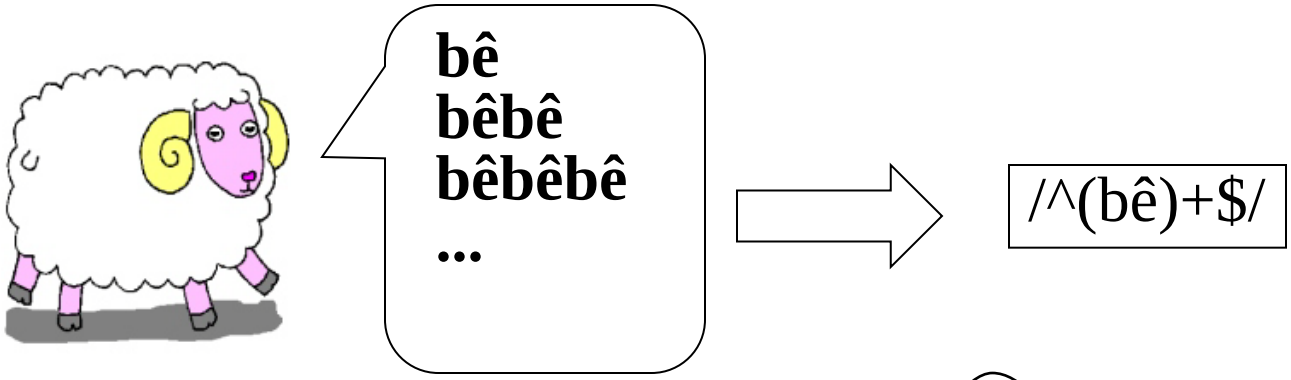

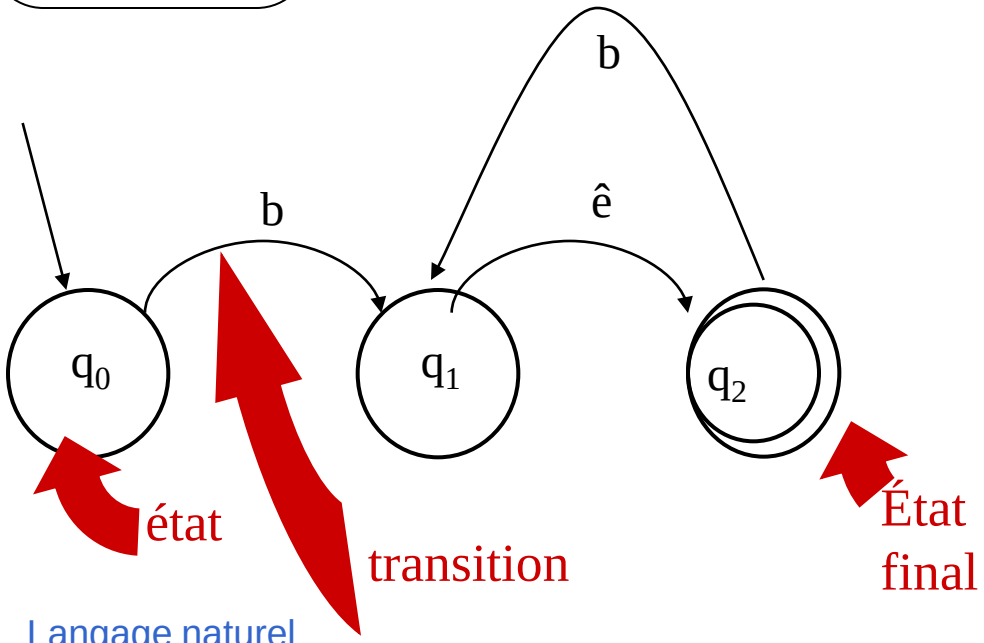

Automate du mouton

- caractéristiques
  - 3 états
  - b et ê appartiennent à l'alphabet
  - q0 est l'état initial
  - q2 est l'état final
  - 3 transitions

Définir un automate à états finis

- Un ensemble d'états : Q
- Un alphabet fini : Σ
- Un état initial q_0
- Un ensemble F d'états finaux $F \subseteq Q$
- Une fonction de transition $\delta(q, i)$ de Q x Σ vers Q

Une autre formulation

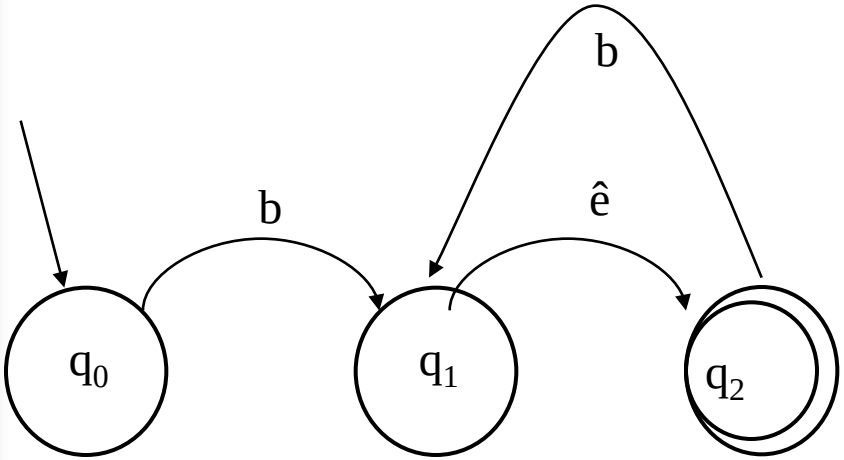

États	b	ê
q_0	q_1	0
q_1	0	q_2
$q_{2:}$:	q_1	0

Reconnaissance

- Une chaîne est reconnue si elle est acceptée par l'automate
  - Commencer à l'état initial
  - Examiner la chaîne en entrée
  - Consulter la table des transitions
  - Aller à l'état suivant et avancer le curseur sur la chaîne
  - Jusqu'à la fin de la chaîne

Chaîne d'entrée

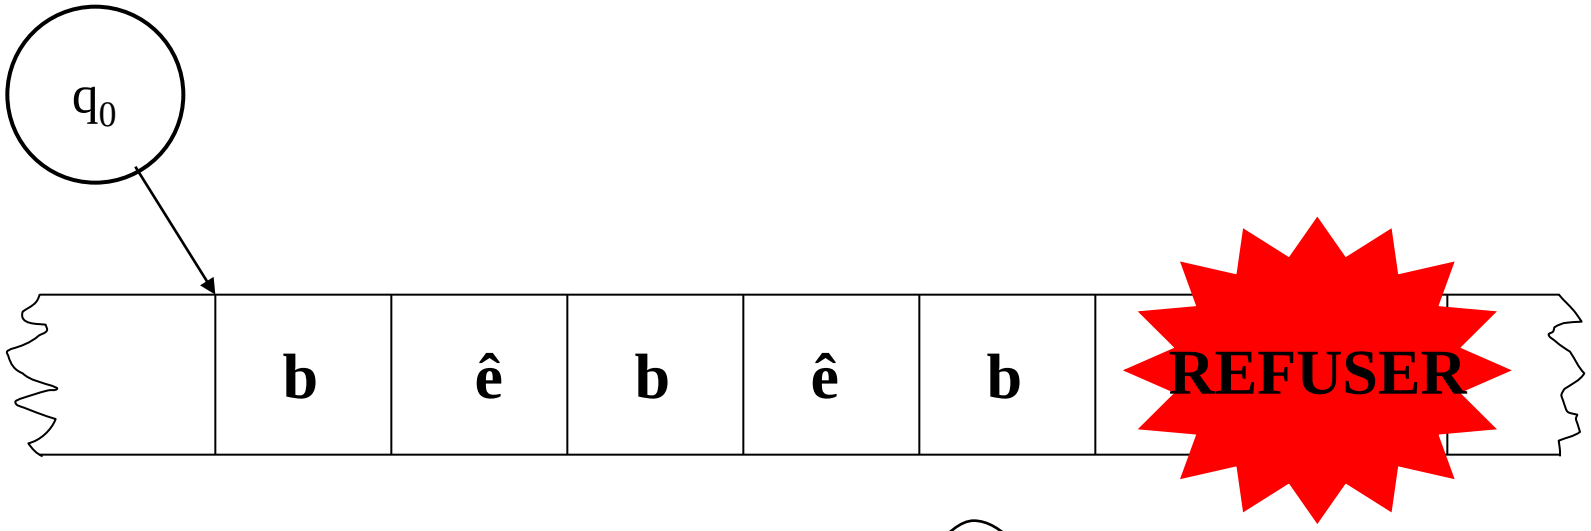

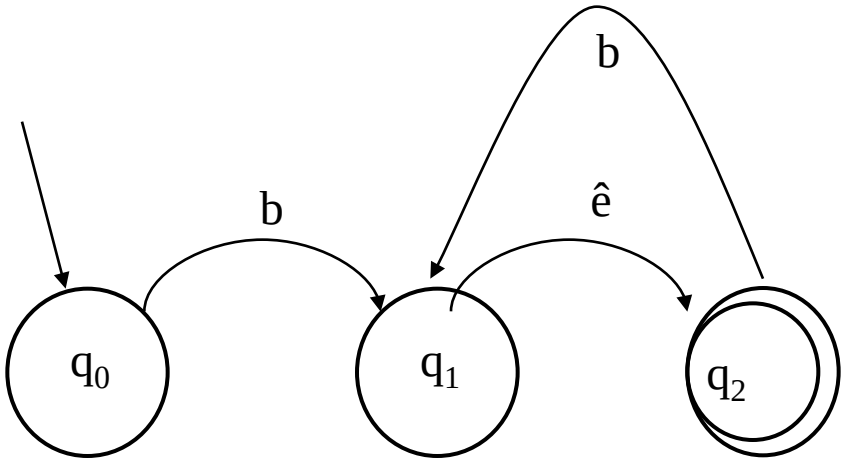

Chaîne d'entrée

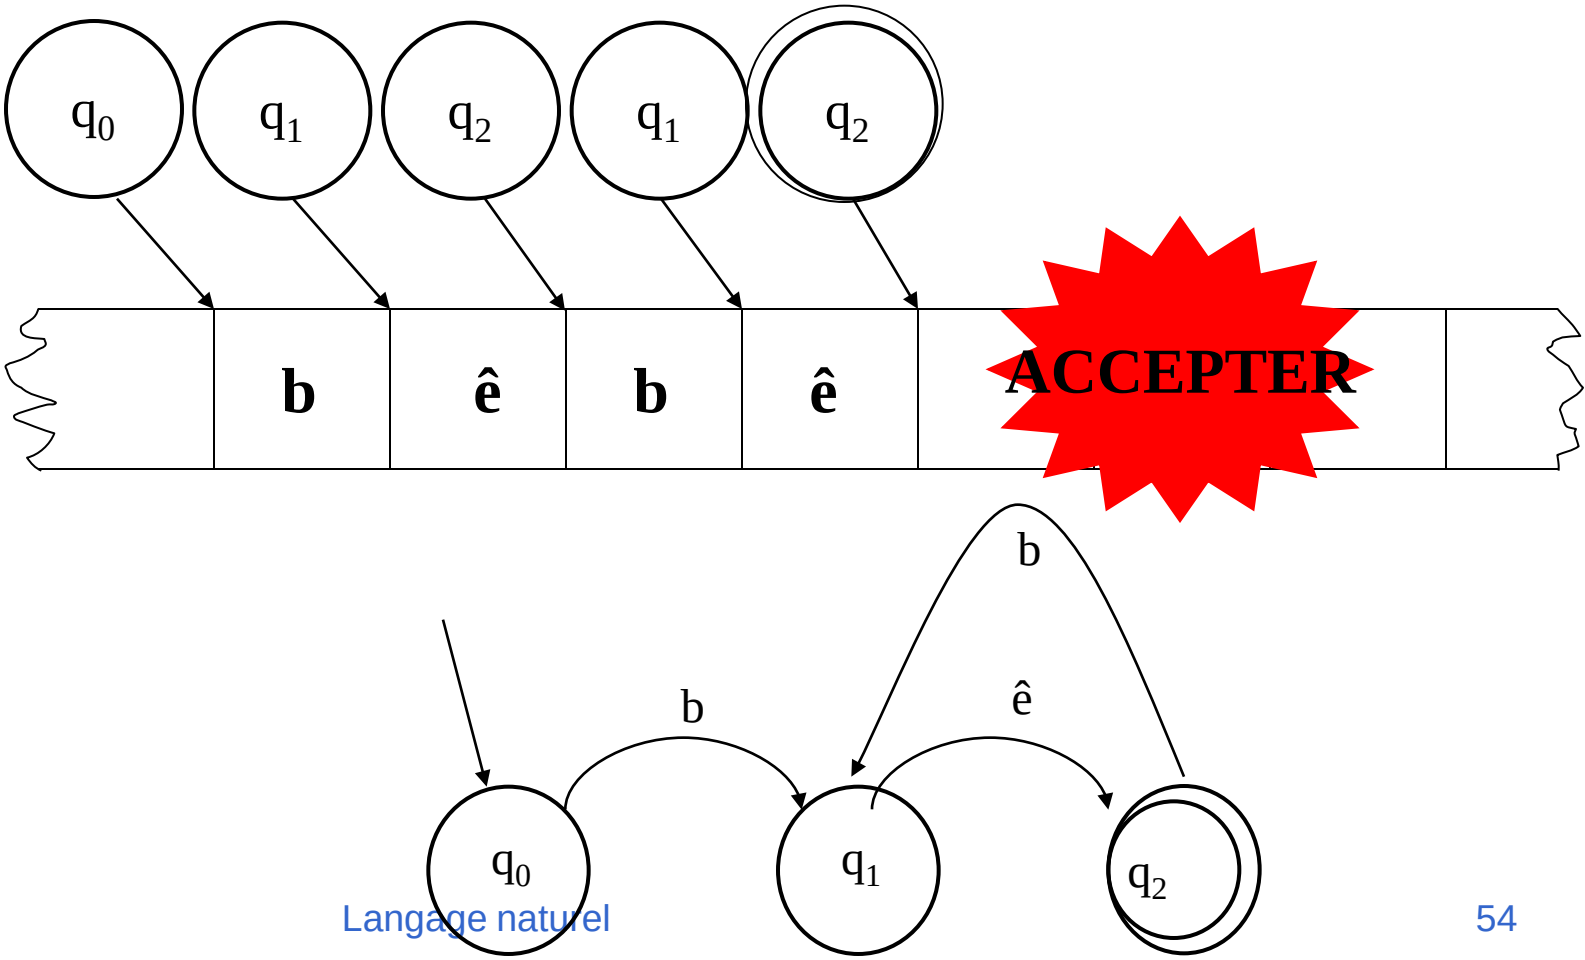

Algorithme de reconnaissance

```
fonction Reconnaitre (chaîne, automate) retourner accepter or
    refuser
  index ← début de chaîne
état_courant ← état initial
     répéter
       Si fin de chaîne alors
                    si état_courant est un état final alors
                                retourner accepter
                    sinon
                                retourner refuser
       sinon si transition [état_courant, chaîne[index]] == 0 alors
           retourner refuser
       sinon
         état_courant ← transition [état_courant, chaîne[index]]
         index ← index + 1
   fin
```