

# ΓΛΩΣΣΙΚΗ ΤΕΧΝΟΛΟΓΙΑ

---

ΕΙΣΑΓΩΓΗ ΣΤΗΝ ΜΟΡΦΟΛΟΓΙΑ

- ΚΑΝΟΝΙΚΕΣ ΕΚΦΡΑΣΕΙΣ
- ΑΥΤΟΜΑΤΑ ΠΕΠΕΡΑΣΜΕΝΩΝ ΚΑΤ/ΣΕΩΝ
- ΜΕΤΑΤΡΟΠΕΙΣ ΠΕΠΕΡΑΣΜΕΝΩΝ ΚΑΤ/ΣΕΩΝ

# Τι είναι η Υπολογιστική Μορφολογία;

---

Η μελέτη της αυτόματης αντιστοίχισης μιας λέξης στις μορφολογικές πληροφορίες που τη χαρακτηρίζουν και το αντίστροφο

- Μορφολογική ανάλυση (parsing)  
*cats*: cat + N + PL
- Μορφολογική παραγωγή (generation)  
cat + N + PL: *cats*
- Χρήσιμα εργαλεία για την επίλυση του προβλήματος είναι
  - τα αυτόματα και
  - οι μετατροπείς πεπερασμένων καταστάσεων

# Γιατί είναι σημαντική;

---

- Ως προεπεξεργασία σε συστήματα επεξεργασίας φυσικής γλώσσας
  - π.χ. εξαγωγή πληροφορίας, μηχανική μετάφραση κτλ.
- Εφαρμογές επεξεργασίας κειμένου
  - π.χ. έλεγχος ορθογραφίας
- Ανάκτηση πληροφορίας
  - π.χ. stemming
- Συστήματα επεξεργασίας ομιλίας
- Χρήση ηλεκτρονικών λεξικών
  - π.χ. λημματοποίηση

# Μορφολογική ταξινόμηση γλωσσών

---

- Απομονωτικές γλώσσες
- Συνθετικές Γλώσσες
  - Συγκολλητικές γλώσσες
  - Πολυσυνθετικές γλώσσες
  - Κλιτές γλώσσες

# Απομονωτικές γλώσσες (isolating)

- Είναι οι γλώσσες που κάθε λέξη αποτελείται από ένα μόρφημα (π.χ. Βιετναμέζικα, Κινέζικα).
- Σε αντίθεση με τις συνθετικές γλώσσες (synthetic) όπου μια λέξη μπορεί να σχηματίζεται από περισσότερα μορφήματα.
- **Μόρφημα** είναι η μικρότερη γλωσσολογική μονάδα που φέρει μορφολογική πληροφορία.
- Σε αυτές τις γλώσσες κάποιες μορφολογικές πληροφορίες μιας λέξης δεν δηλώνονται εμφανώς (π.χ. στα κινέζικα ο χρόνος και ο αριθμός)

	<i>gou</i>	<i>bu</i>	<i>ai</i>	<i>chi qingcai</i>
(the)	<i>dog/s</i>	<i>do/does/did</i>	<i>not</i>	<i>like eat vegetables</i>

# Πολυσυνθετικές γλώσσες (polysynthetic)

---

- Είναι οι γλώσσες που κάθε λέξη αποτελείται από πολλά μορφήματα και αντιστοιχούν σε ολόκληρη πρόταση (γλώσσες Εσκιμώων, όπως η γλώσσα Yupik κεντρικής Αλάσκας)

*qaya:liyu:lu:ni*

‘ήταν τέλειος (-yu-) στο να φτιάχνει (-li-) καγιάκ (qaya:-)’

# Συγκολλητικές γλώσσες (agglutinative)

---

- Είναι οι γλώσσες που οι λέξεις τους σχηματίζονται από πολλά μορφήματα με ευδιάκριτα όρια (Τούρκικα, Ουγγρικά, Σουαχίλι)
- Κάθε μόρφημα εμπεριέχει μια μόνο μορφολογική πληροφορία

*Cop+luk+ler+imiz+de+ki+ler+den+mi+y+di*

σκουπίδια+AFF+**PL**+1P/PL+LOC+REL+**PL**+ABL+INT+AUX+PAST

‘ήταν από εκείνα που ήταν στους σκουπιδοντενεκέδες μας;’

# Κλιτές γλώσσες (inflectional)

---

- Είναι οι γλώσσες που χρησιμοποιούν μεγάλο αριθμό μορφημάτων.
- Ένα μόρφημα εκφράζει ταυτόχρονα πολλές μορφολογικές κατηγορίες. (Ελληνικά, Λατινογενείς γλώσσες)

*παίζ-οντ*: 3o+PL+ACT+PRES/PAST

*vogli-o*: 1o+SNG+ACT+PRES/PAST

# Λήμμα (Lemma)

---

- **Λήμμα** είναι ένα σύνολο μορφών της ίδιας λέξης. Οι μορφές έχουν
  - την ίδια ρίζα,
  - το ίδιο μέρος του λόγου,
  - την ίδια έννοια.
- Παράδειγμα: Οι παρακάτω λέξεις έχουν το ίδιο λήμμα (*παίζω*):  
*παίζω, παίζεις, παίζει, παίζουμε, ἐπαίξε...*

# Παραγωγή (derivation)

---

- Ο σχηματισμός λέξεων διαφορετικών κατηγοριών από το ίδιο λήμμα

*establish* (V)

*establish+ment* (N)

*establish+ment+ary* (Adj)

*establish+ment+ari+an* (N)

*establish+ment+ari+an+ism* (N)

*dis+establish+ment+ari+an+ism* (N)

*anti+dis+establish+ment+ari+an+ism* (N)

# Προσφυματοποίηση (affixation)

---

- Και η κλίση και η παραγωγή στηρίζονται στην προσφυματοποίηση (εισαγωγή προθέματος, κατάληξης, ενθέματος).
- Πρόθεμα (prefix): *ξε-πλένω*
- Ένθεμα (infix): *δι-έ-σχισα*
- Κατάληξη (suffix): *κατεργαρ-άκος*

# Μόρφημα

---

- Μόρφημα: ΓΕΝΙΚΗ
- Μορφές:
  - Διαφορετικές μορφές ανάλογα με το λήμμα και τα χαρακτηριστικά του  
 $\{-\alpha\varsigma\}$  /  $\{-\text{ov}\}$  /  $\{-\text{ou}\varsigma\}$  /  $\{-\alpha\}$  ...  
*χώρ-ας*      *λόγ-ον*      *λάθ-ονς*      *πατέρ-α*
  - Διαφορετικές μορφές για το ίδιο λήμμα  
*γράφ*  $\{-\text{ontan}\}$  /  $\{-\text{ontane}\}$  /  $\{-\text{ontousan}\}$

# Κανονικές εκφράσεις (Regular Expressions)

[www.regexpal.com](http://www.regexpal.com)

- Οι **κανονικές εκφράσεις** είναι αλγεβρικές εκφράσεις που αντιπροσωπεύουν ένα πρότυπο (pattern) ακολουθίας συμβολοσειρών (strings).
- Χρησιμοποιούνται
  - για την αναζήτηση συμβολοσειρών σε κείμενο
  - για τον τυπικό ορισμό μιας γλώσσας
- Παραδείγματα
  - Απλή ακολουθία χαρακτήρων  
/δώρο/                                  *Δώσε μου το δώρο μου.*  
/!/    *Δεν είσαι καλά!*  
/αδερφό μου/                        *Μίλησα στον αδερφό μου χτές.*
  - Πολλαπλή ταυτοποίηση  
/[Δδ]ώρο/                              *δώρο, Δώρο*  
/[0123456789]/                        *όλα τα ψηφία*  
/[3-5]/                                    *3,4,5 (τα ψηφία από το 3 ως το 5)*

# ΚΕ: Παραδείγματα (συν)

---

## □ Άρνηση

/[^α]/                            Λες σαχλαμάρες

/[^0-9]/                         ταντοποιείται με όλα εκτός από ψηφία

## □ Προαιρετικότητα

/πατέρας?/                    πατέρα, πατέρας (ο χαρ/ρας ακριβώς πριν από  
το ? μπορεί να υπάρχει ή όχι)

## □ Επανάληψη

■ ο χαρ/ρας ακριβώς πριν από το \* μπορεί να υπάρχει καμία ή περισσότερες φορές

/μπα\*/                         μπ, μπα, μπαα, μπααα, μπαααα, ...

/[αβ]\*/                         αααα, ββββββββ, αβαβαβαβ, κενό, ...

■ (ο χαρ/ρας ακριβώς πριν από το ! μπορεί να υπάρχει μία ή περισσότερες φορές)

/μπα!/                         μπα, μπαα, μπααα, μπαααα, ...

■ Το ! πολλές φορές συναντάται ως +

# ΚΕ: Παραδείγματα (συν)

---

- Χαρακτήρας μπαλαντέρ (.)  
/φ.λο/                    φίλο, φύλο
- Αρχή γραμμής κειμένου  
/^Το/                    ... . To σπίτι μου...
- Τέλος γραμμής κειμένου  
/ωραίο\\$/                ....είναι ωραίο. Επίσης...
- Διάζευξη  
/σκύλος|γάτα/        *Αυτός είναι ο σκύλος και αυτή είναι η γάτα μου.*  
/σκύλο(ς|ι)/            σκύλος, σκύλοι
- Αρχή-τέλος λέξης  
/\bστο\b/                *Με αποστομώνει στο τέλος.*

# ΚΕ: Προτεραιότητα τελεστών

---

παρενθέσεις ()

μετρητές ? + \*

αρχή/ τέλος γραμμής/λέξης ^ \$ \b

διάζευξη |

# Παραδείγματα

---

- Έστω ότι θέλω να φτιάξω μια ΚΕ που να βρίσκει το άρθρο *to* μέσα σε ένα κείμενο.

/το/                          Δεν βρίσκει το *To*.

/[Ττ]ο/                          Βρίσκει και τα: *στο*, *απότομο* κλπ.

/\b[Tτ]ο\b/

□ [^A-Za-z][A-Za-z]+ing[^A-Za-z]

□ [^A-Za-z][Tt]he[^A-Za-z]

- Για κάθε μια από τις ακόλουθες ΚΕ δώστε δυο συμβολοσειρές που ανήκουν στην γλώσσα που αναπαριστά η ΚΕ και δυο που δεν ανήκουν.

1)  $a^*b^*$

2)  $a(ba)^*a$

# Αυτόματα πεπερασμένων καταστάσεων (Finite State Automata - FSAs)

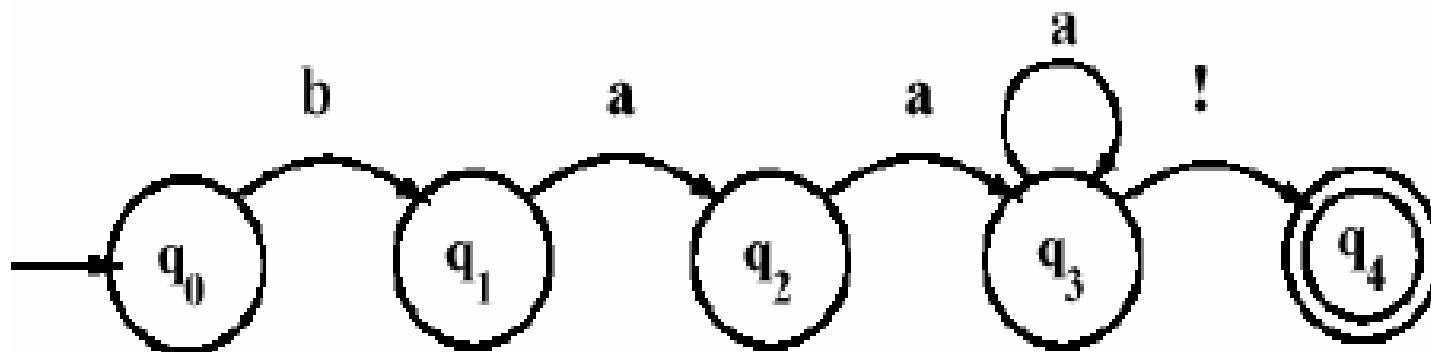
---

- Ένα ΑΠΚ είναι ένας γράφος που αποτελείται από
  - κόμβους (καταστάσεις) και
  - κατευθυνόμενα βέλη (μεταβάσεις), που αντιστοιχούν στα σύμβολα ενός αλφαριθμητικού αλφαριθμητικού
- Μια κατάσταση ορίζεται ως αρχική
  - Συμβολίζεται με ένα εισερχόμενο βέλος
- Μια ή περισσότερες καταστάσεις ορίζονται ως τελικές ή αποδεκτές
  - Συμβολίζονται με διπλό κύκλο

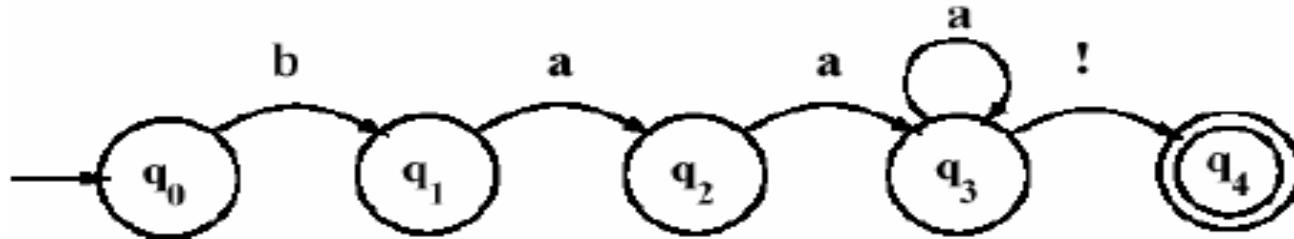
# ΑΠΚ: Παράδειγμα

---

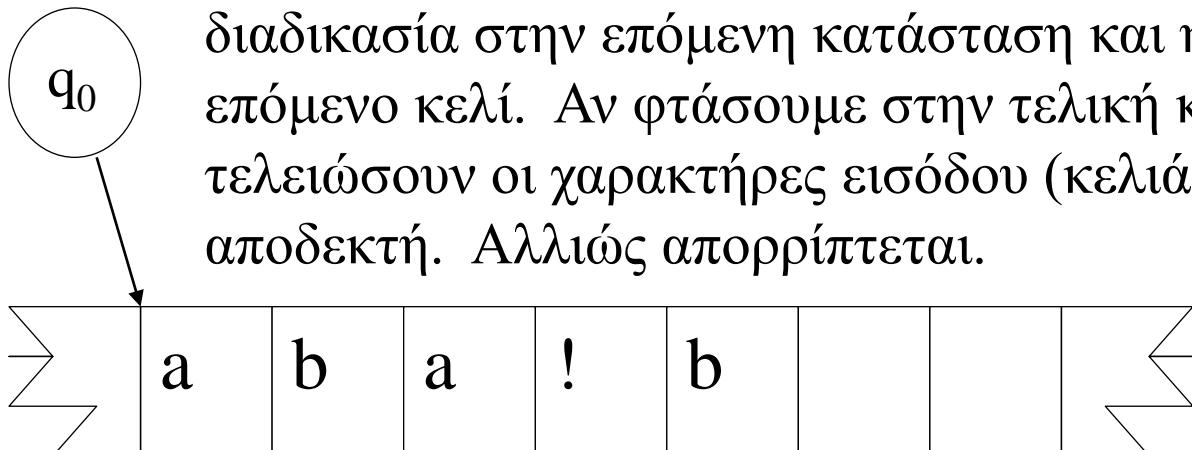
- baa! baaa! baaaa!
- Αυτό το αυτόματο είναι ισοδύναμο με την κανονική έκφραση  $/baaa^*\backslash!/\!$



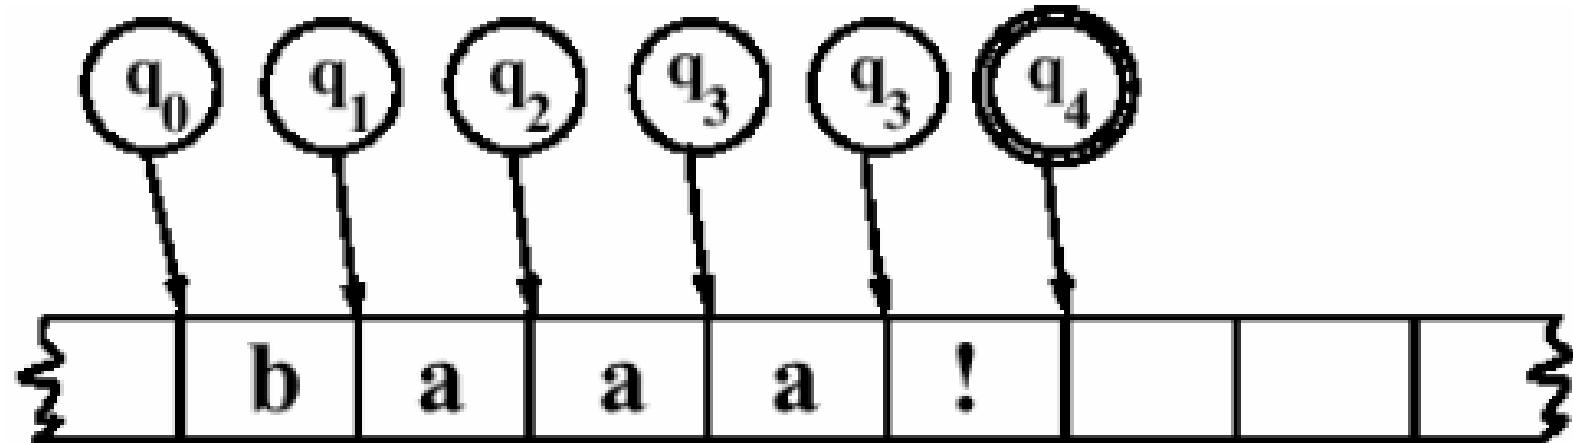
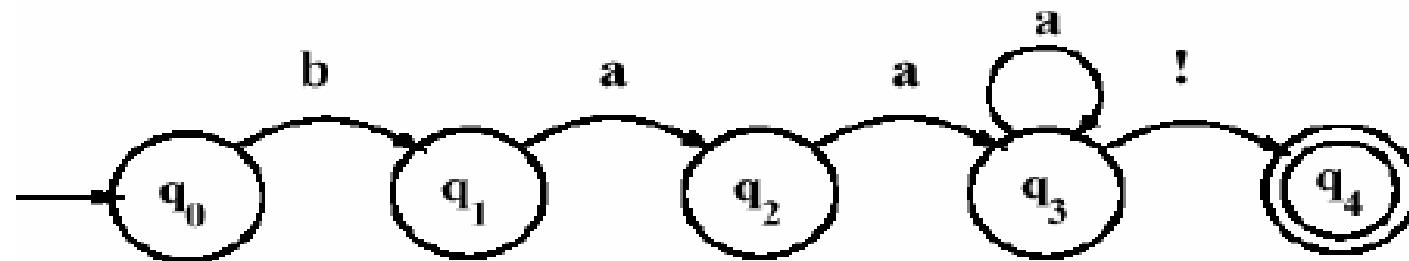
# Αναγνώριση αλφαριθμητικών με ΑΠΚ: Μη αποδεκτή λέξη



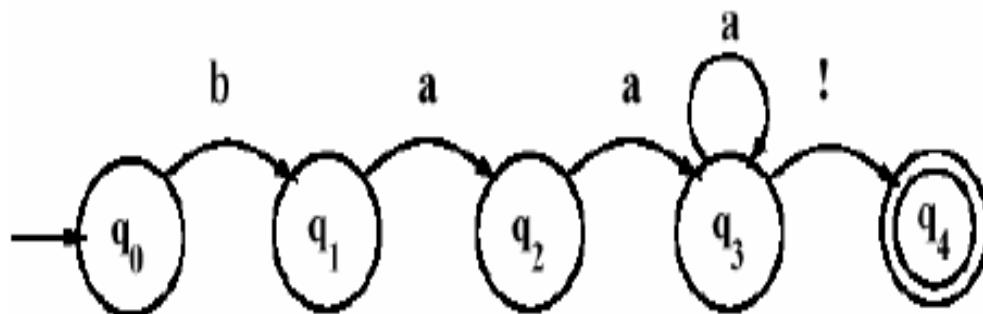
Σε κάθε κελί της ταινίας υπάρχει και ένας χαρακτήρας.  
Η αρχική κατάσταση δείχνει στην αρχή του πρώτου κελιού.  
Αν ο χαρακτήρας εισόδου ταιριάζει με τον χαρακτήρα στο βέλος  
της αντίστοιχης κατάστασης του αυτομάτου, περνάει η  
διαδικασία στην επόμενη κατάσταση και η ταινία προχωράει στο  
επόμενο κελί. Αν φτάσουμε στην τελική κατάσταση όταν μας  
τελειώσουν οι χαρακτήρες εισόδου (κελιά), τότε η λέξη είναι  
αποδεκτή. Άλλιώς απορρίπτεται.



# Αναγνώριση αλφαριθμητικών με ΑΠΚ: Αποδεκτή λέξη



# Πίνακας Μετάβασης Καταστάσεων



	Input		
State	b	a	!
0	1	0	0
1	0	2	0
2	0	3	0
3	0	3	4
4:	0	0	0

# Τυπικός Ορισμός ενός ΑΠΚ

---

- $Q$ : ένα πεπερασμένο σύνολο καταστάσεων ( $q_0, q_1, \dots$ )
- $\Sigma$ : ένα πεπερασμένο αλφάβητο συμβόλων εισόδου
- $q_0$ : η αρχική κατάσταση
- $F$ : οι τελικές καταστάσεις (υποσύνολο του  $Q$ )
- $\delta(q,i)$ : η συνάρτηση μετάβασης καταστάσεων.  
Δεδομένης μιας κατάστασης  $q$  και ενός συμβόλου εισόδου  $i$ , επιστρέφει μια νέα κατάσταση  $q'$

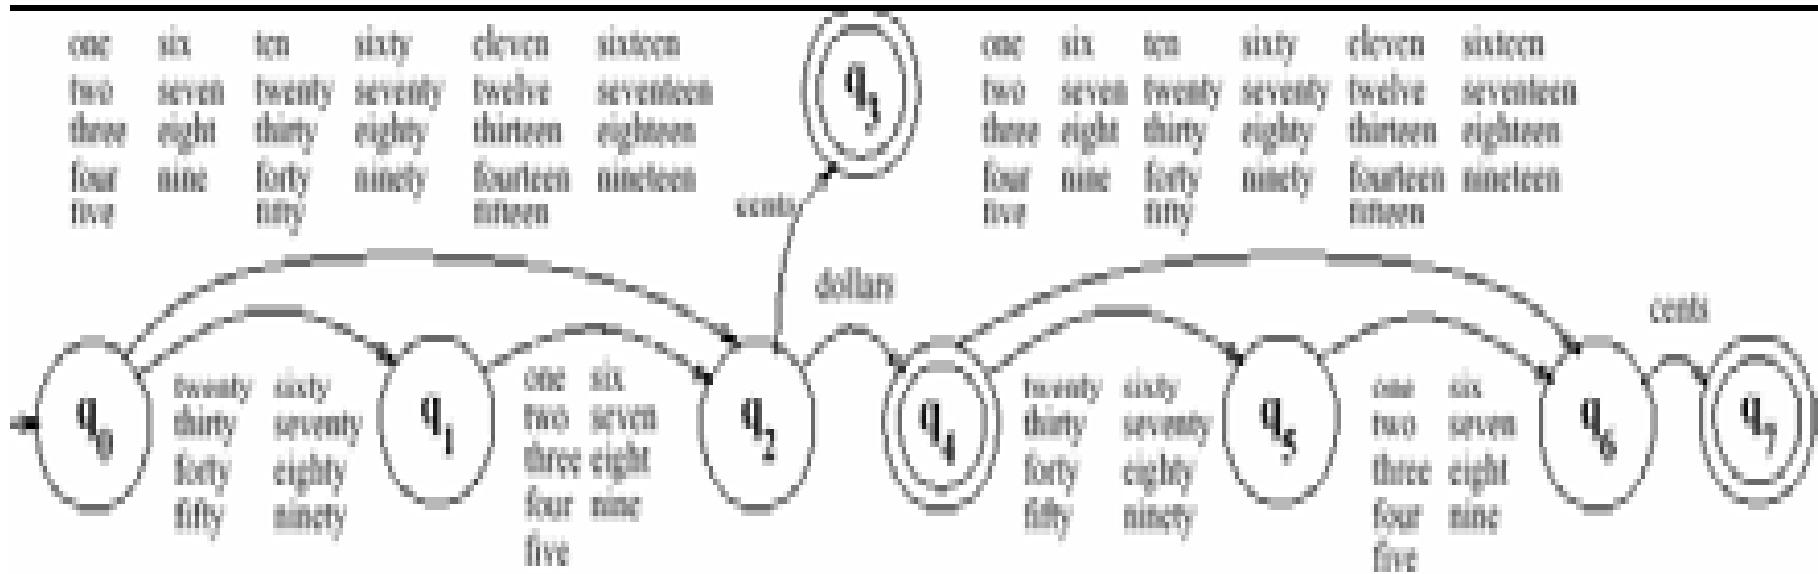
# Τυπικές Γλώσσες (Formal Languages)

---

- Η **τυπική γλώσσα** είναι ένα σύνολο από αλφαριθμητικά (λέξεις).
- Κάθε **λέξη** απαρτίζεται από σύμβολα.
- Το σύνολο των συμβόλων είναι το **αλφάβητο** της γλώσσας.
- Το αλφάβητο του προηγούμενου παραδείγματος είναι το σύνολο  $\Sigma = \{a, b, !\}$
- Η τυπική γλώσα του προηγούμενου παραδείγματος είναι άπειρο σύνολο  
 $L = \{baa!, baaa!, baaaa!, baaaaaa!, \dots\}$

# Παράδειγμα ΑΠΚ

Το αλφάβητο μπορεί να είναι και υψηλότερου επιπέδου, να αποτελείται από λέξεις αντί για σύμβολα.



Τα αγγλικά χρηματικά ποσά (μέχρι το ποσό \$99.99)

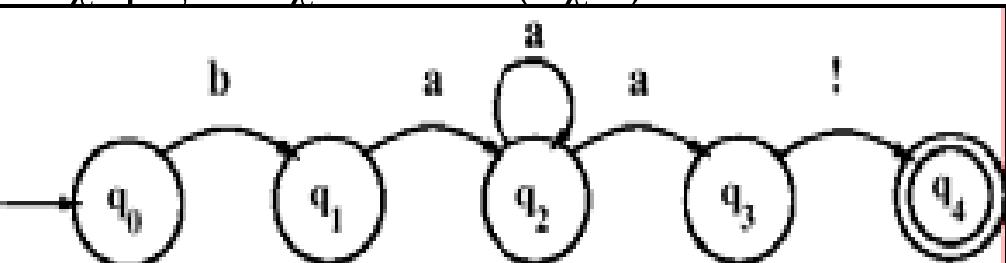
# Ντετερμινιστικά-Μη ντετερμινιστικά ΑΠΚ

**Deterministic FSA (DFSA):** Η αναγνώριση μιας συμβολοσειράς δεν υπόκειται σε επιλογές.

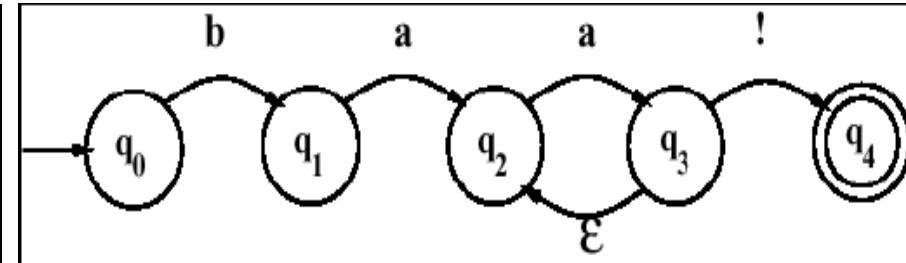


**Non-Deterministic FSA (NFSA):**

- Όταν από μία κατάσταση και με την ίδια είσοδο, το FSA έχει περισσότερες από μια επιλογές για την κατάσταση που θα μετακινηθεί (σχ.1).
- Όταν έχω μεταβάσεις  $\epsilon$  ( $\epsilon$ -transitions). Οι μεταβάσεις αυτές (κενά τόξα) με μεταφέρουν από μια κατάσταση σε άλλη χωρίς να λαμβάνεται υπόψη η είσοδος ή χωρίς να έχω είσοδο (σχ.2).



Σχήμα 1



Σχήμα 2

# Πίνακας Μετάβασης NFSA

- Προστίθεται μια επιπλέον στήλη για το κενό τόξο
- Οι μεταβάσεις είναι σύνολα καταστάσεων

	Input			
State	b	a	!	ε
0	1	∅	∅	∅
1	∅	2	∅	∅
2	∅	2,3	∅	∅
3	∅	∅	4	2
4:	∅	∅	∅	∅

# Αναγνώριση με NFSA

---

- Μια λέξη μπορεί να απορρίπτεται λανθασμένα από ένα NFSA επειδή επιλέχτηκε το λάθος τόξο. Αυτό αντιμετωπίζεται
  - Με σήμανση του κελιού της ταινίας στο οποίο έχουμε φτάσει μέχρι την στιγμή που εμφανίζεται η μη ντετερμινιστική επιλογή. Έτσι, αν αποδειχθεί ότι κάναμε λάθος επιλογή μπορούμε να γυρίσουμε πίσω και να επιλέξουμε διαφορετικό μονοπάτι.
  - Με έλεγχο της συνέχειας της εισόδου. Κοιτάω από πριν πώς εξελίσσεται η είσοδος και επιλέγω ανάλογα.
  - Με παράλληλη εξέταση εναλλακτικών μονοπατιών.

# Αναγνώριση με NFSA

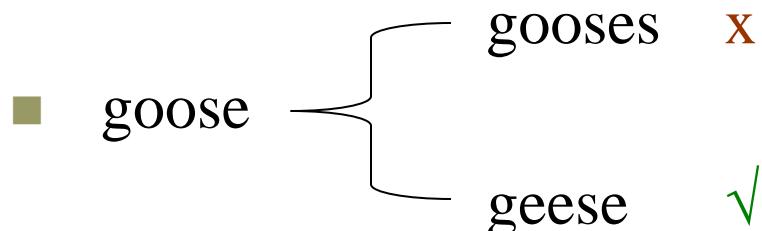
---

- Η αναγνώριση συμβολοσειρών με NFSA μπορεί να θεωρηθεί ως αναζήτηση σε ένα χώρο καταστάσεων
- Η σειρά με την οποία εξετάζονται οι καταστάσεις (η απόφαση για το ποιο μονοπάτι θα ακολουθηθεί) επηρεάζει την επίδοση
- Αναζήτηση σε βάθος ή αναζήτηση σε πλάτος
- Για μεγάλους χώρους καταστάσεων είναι απαραίτητο να χρησιμοποιηθούν πιο προηγμένες τεχνικές αναζήτησης (Δυναμικός προγραμματισμός ή A\*)



# Μορφολογική Ανάλυση-Μορφολογική Αναγνώριση

- **Μορφολογική Αναγνώριση:** Αποδέχεται ή απορρίπτει λέξεις



- **Μορφολογική Ανάλυση (Parsing):** Εξάγει μορφολογική πληροφορία σχετικά με μία λέξη (λήμμα, μορφολογικά χαρακτηριστικά)
  - geese: goose + N + PL
  - cats: cat + N + PL
  - ground: ground +N +SG
- **Μορφολογική Σύνθεση (Generation/Synthesis):** Σχηματίζει μια λέξη από το λήμμα και τα μορφολογικά της χαρακτηριστικά (η αντίθετη διαδικασία από την ανάλυση)

# Μορφολογικός Αναλυτής

---

- Ένας μορφολογικός αναλυτής αποτελείται από
  - Λεξικό: μία λίστα από λήμματα ή καταλήξεις μιας γλώσσας, μαζί με τη βασική πληροφορία που τα χαρακτηρίζουν
    - Π.χ.      dog: reg-noun
    - goose: irreg-sg-noun
    - geese: irreg-pl-noun
    - s: plural-suffix
  - Μορφοτακτικοί κανόνες: ένα μοντέλο διάταξης των μορφημάτων που καθορίζει ποιες κατηγορίες μορφημάτων ακολουθούνται από άλλες κατηγορίες (π.χ. ότι το μόρφημα του πληθυντικού στα αγγλικά ακολουθεί το ουσιαστικό)
  - Ορθογραφικοί κανόνες: μοντελοποιούν ορθογραφικές αλλαγές που συμβαίνουν στις λέξεις μίας γλώσσας  
(π.χ. city+s -> cities)

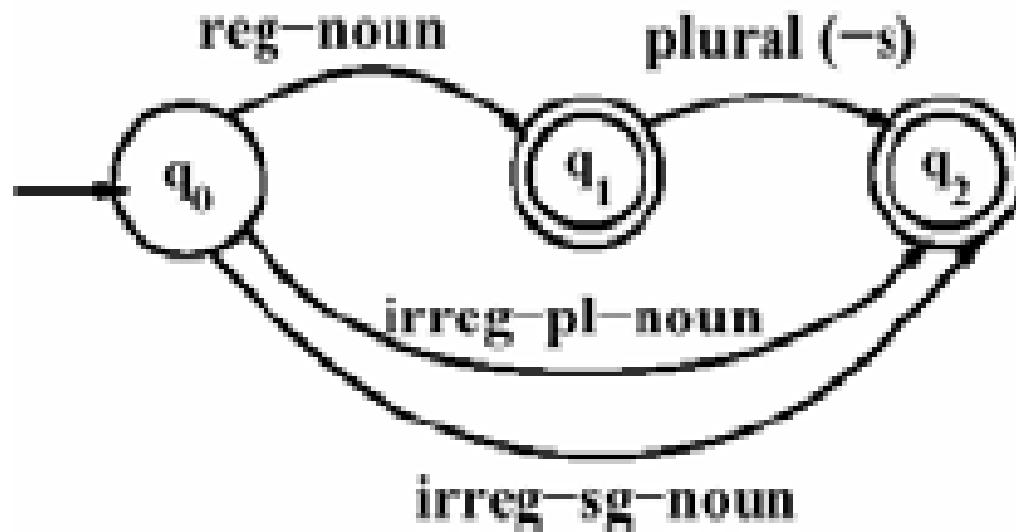
# Λεξικό

---

- Στην πιο απλή περίπτωση είναι ένα σύνολο από όλες τις λέξεις της γλώσσας:
  - a, AAA, AA, Aachen, aardvark, aardwolf...
- Δεν είναι πρακτικό να αποθηκεύσουμε όλες τις δυνατές λέξεις μιας γλώσσας
  - Για μερικές γλώσσες (Φιλανδικά, Τουρκικά) αυτό είναι αδύνατο
  - Συνήθως αποθηκεύονται μόνο οι ρίζες και οι καταλήξεις
- Στην ιδεατή περίπτωση όλες οι πιθανές λέξεις (π.χ. ακρωνύμια, κύρια ονόματα κτλ.) πρέπει να βρίσκονται στο λεξικό

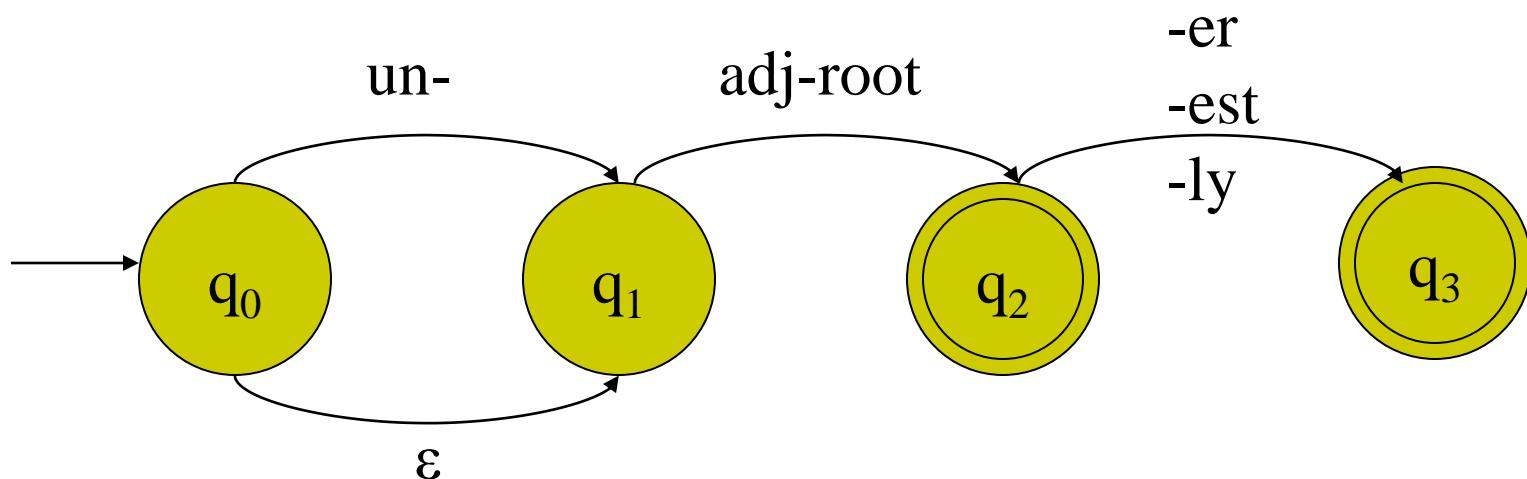
# Μορφοτακτικοί κανόνες

- Συνήθως αναπαριστάνονται με ΑΠΚ
- Π.χ. Ένα απλό FSA για το σχηματισμό πληθυντικού αριθμού στα Αγγλικά:



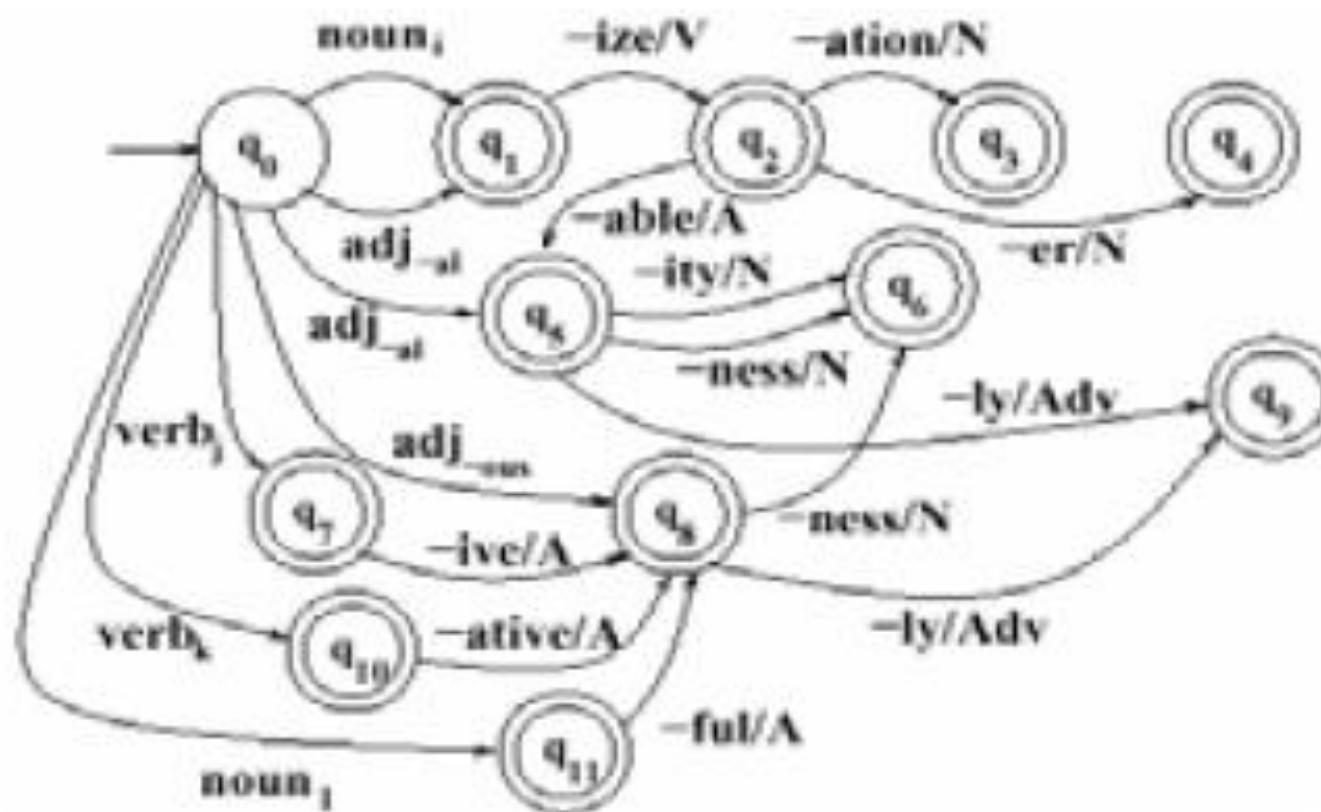
# Μορφολογία αγγλικών επιθέτων

- clear, clearer, clearest, clearly, unclear, unclearly
- cool, cooler, coolest, coolly
- big, bigger, biggest, **unbig, bigly**
- red, redder, reddest, **redly**
- real, really, **realer, realest**

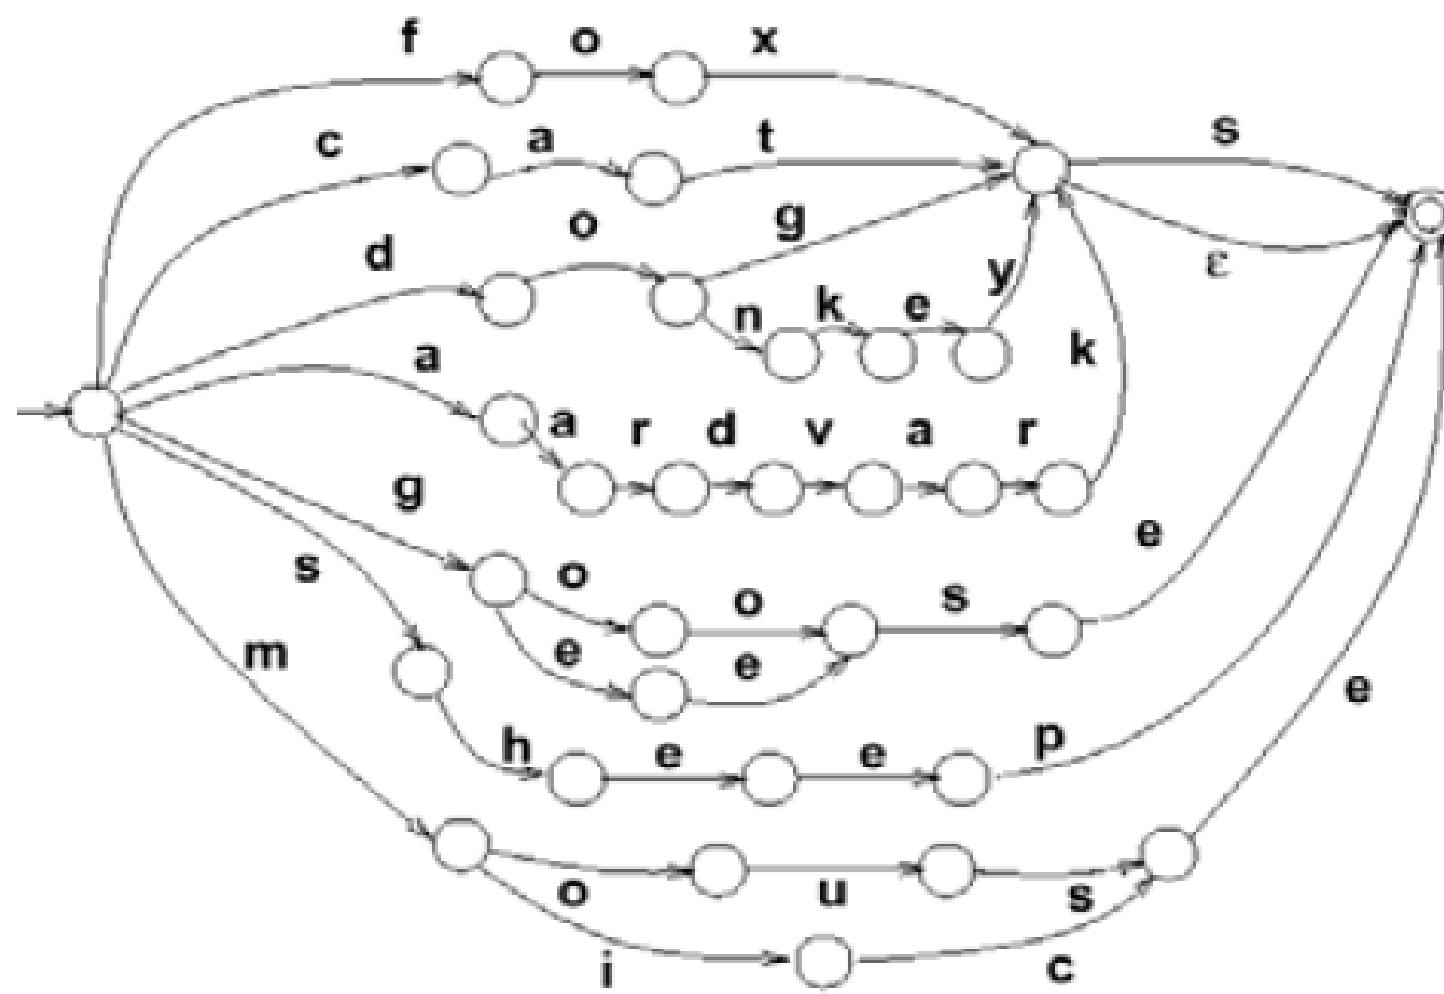


# Πολυπλοκότητα

- Ένα ΑΠΚ για περιγραφή τμήματος της αγγλικής παραγωγικής μορφολογίας

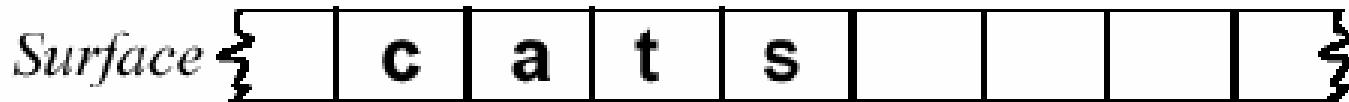
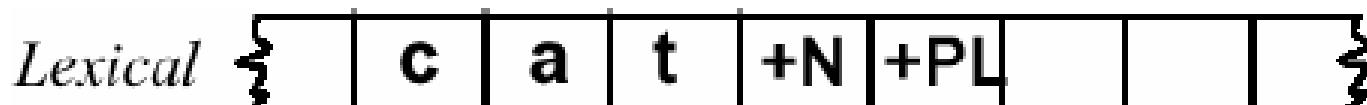


# Μορφολογική Αναγνώριση με ΑΠΚ



# Μορφολογική Ανάλυση

- Μορφολογία 2 επιπέδων (Two-level Morphology)
- Επιφανειακό επίπεδο λέξης (surface level): η λέξη όπως αυτή εμφανίζεται σε ένα κείμενο
- Λεξικολογικό επίπεδο λέξης (lexical level): μια ακολουθία (συνένωση) μορφημάτων που σχηματίζουν την λέξη
- Η μορφολογία 2 επιπέδων αναπαριστά μια λέξη σαν μια αντιστοιχία ανάμεσα στο λεξικολογικό και το επιφανειακό επίπεδο



# Μετατροπέας Πεπερασμένων Καταστάσεων (Finite State Transducer - FST)

---

- Ο ΜΠΚ πραγματοποιεί την αντιστοιχία μεταξύ των 2 επιπέδων
- Ο ΜΠΚ είναι ένα αυτόματο με 2 ταινίες που αναγνωρίζει ή παράγει **ζευγάρια** συμβολοσειρών.
- Ο ΜΠΚ είναι μια μηχανή που διαβάζει μια συμβολοσειρά και παράγει μια άλλη.

# Μετατροπέας Πεπερασμένων Καταστάσεων

---

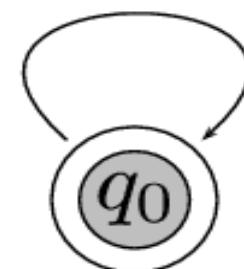
- Σαν μηχανή αναγνώρισης, ο ΜΠΚ παίρνει σαν είσοδο δύο συμβολοσειρές και βγάζει ως έξοδο
  - Αποδοχή, εάν το ζεύγος των συμβολοσειρών εμπεριέχεται στην γλώσσα, και
  - Απόρριψη, εάν δεν εμπεριέχεται
  
- Σαν μηχανή μετάφρασης, ο ΜΠΚ παίρνει μια συμβολοσειρά και παράγει μια άλλη συμβολοσειρά

# Τυπικός ορισμός ενός ΜΠΚ

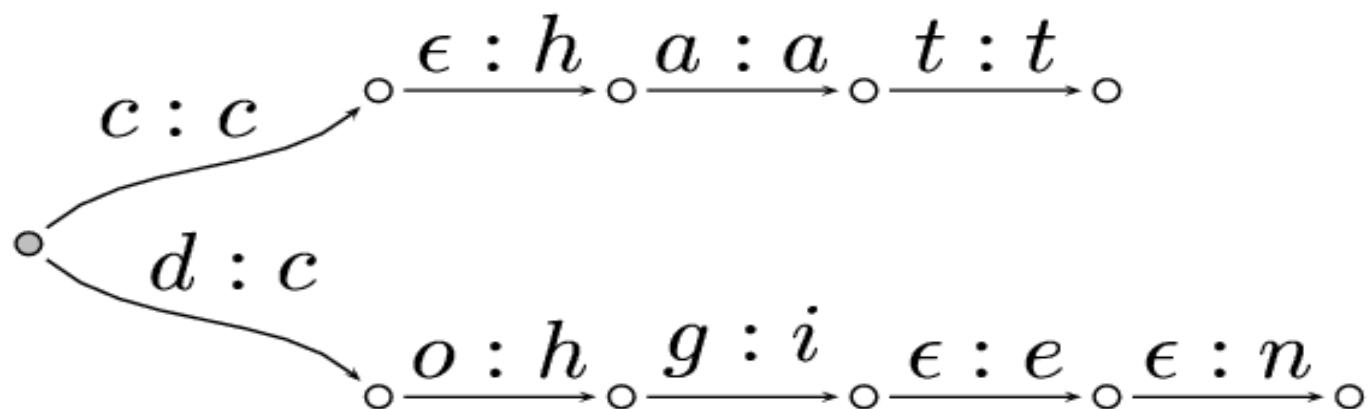
- **Q:** ένα πεπερασμένο σύνολο καταστάσεων ( $q_0, q_1, \dots$ )
- **$\Sigma$ :** ένα πεπερασμένο αλφάβητο ζευγών  $i:o$ , όπου
  - $i$  είναι ένα σύμβολο από το αλφάβητο εισόδου και
  - $o$  ένα σύμβολο από το αλφάβητο εξόδου  
(το ε μπορεί να ανήκει και στα δύο αλφάβητα)
  - Π.χ.  $\Sigma = \{a:a, b:b, !:!, a:!, a:b, b:a, a:\epsilon, \epsilon:!\}$
- **$q_0$ :** η κατάσταση εκκίνησης
- **F:** οι τελικές καταστάσεις (υποσύνολο του Q)
- **$\delta(q,i:o)$ :** η συνάρτηση μετάβασης. Δεδομένης μίας κατάστασης  $q$  και μίας εισόδου  $i$ , επιστρέφει μία νέα κατάσταση  $q'$ .

Example: The uppercase transducer

$$a : A, b : B, c : C, \dots$$



Example: English-to-French

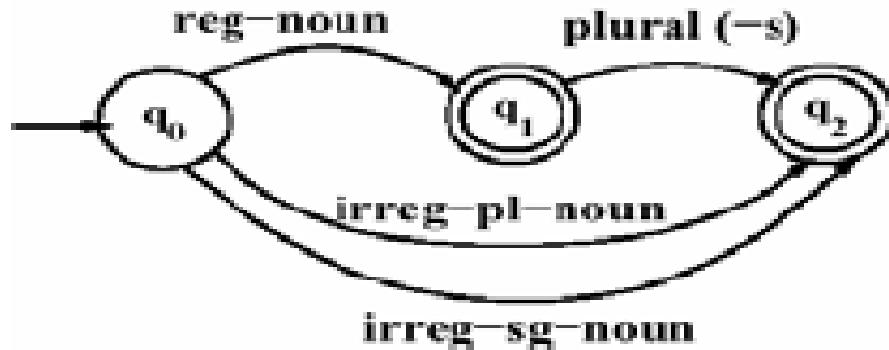


# ΜΠΚ και Μορφολογία 2 επιπέδων

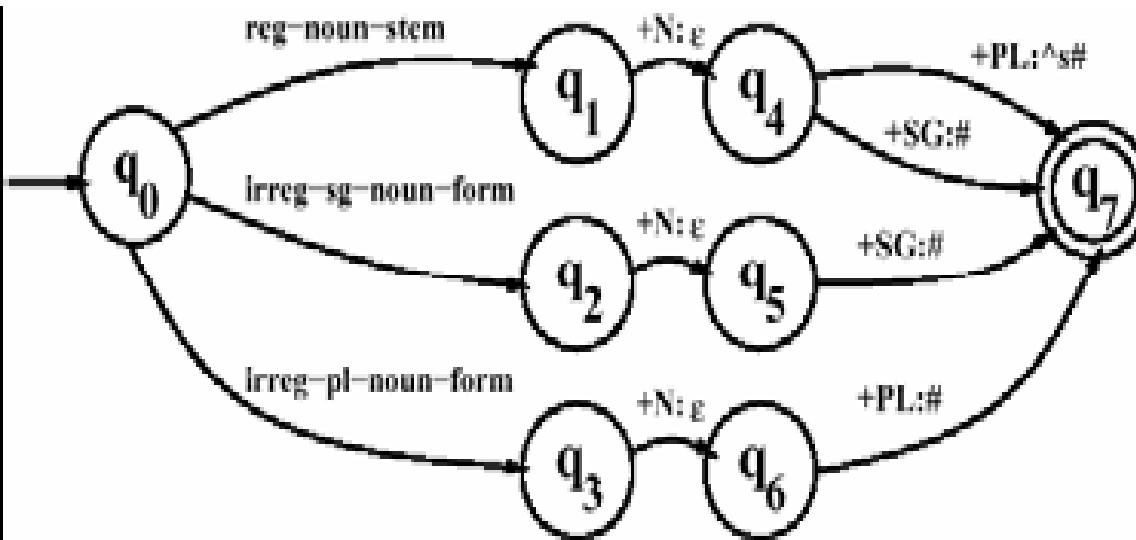
---

- Είναι βολικό να θεωρήσουμε ότι ένας ΜΠΚ έχει δύο ταινίες
  - Λεξικολογική ταινία (lexical tape)
  - Επιφανειακή ταινία (surface tape)
- Κάθε ζεύγος συμβόλων a:b εκφράζει πώς αντιστοιχίζεται ένα σύμβολο της μίας ταινίας σε κάποιο σύμβολο της άλλης
- Στην λεξικολογική ταινία υπάρχουν τα σύμβολα του αριστερού μέρους των ζευγών a:b
- Στην επιφανειακή ταινία υπάρχουν τα σύμβολα του δεξιού μέρους των ζευγών a:b
- Σύμβολα όπως το *a:a* καλούνται **default pairs** και συνήθως αναπαρίστανται απλά ως *a*.

# Από ΑΠΚ σε ΜΠΚ



Το ΑΠΚ για τον σχηματισμό του πληθυντικού στα Αγγλικά

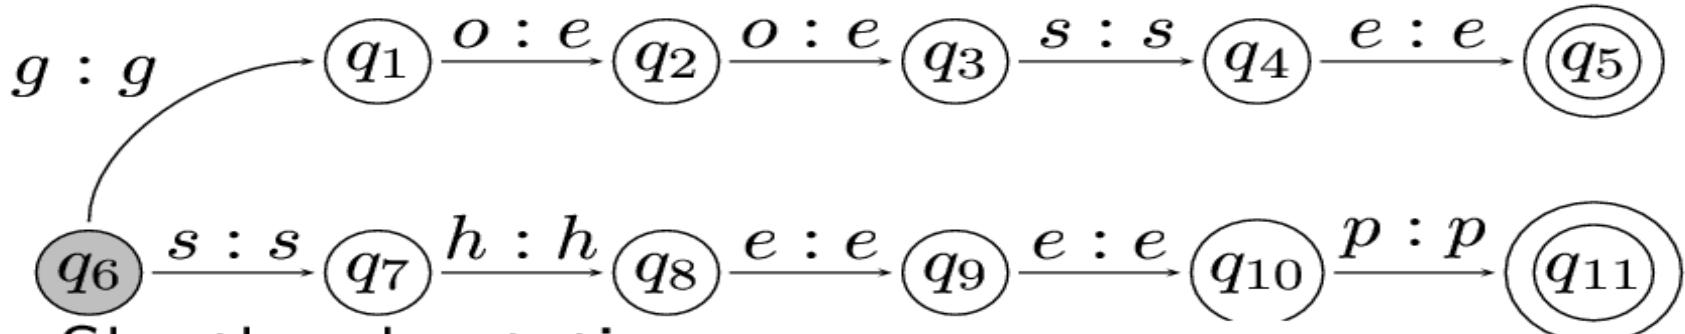


Η εξέλιξη του ΑΠΚ σε ΜΠΚ με την προσθήκη των μορφ/κών χαρακτηριστικών +SG, +PL, +N.  
Τα χαρ/κά αυτά σχηματίζουν ζευγάρια με τα σύμβολα ε (κενή συμβολοσειρά) ^ (όριο μορφήματος) # (όριο λέξης) γιατί δεν εμφανίζονται στην ταινία εξόδου.

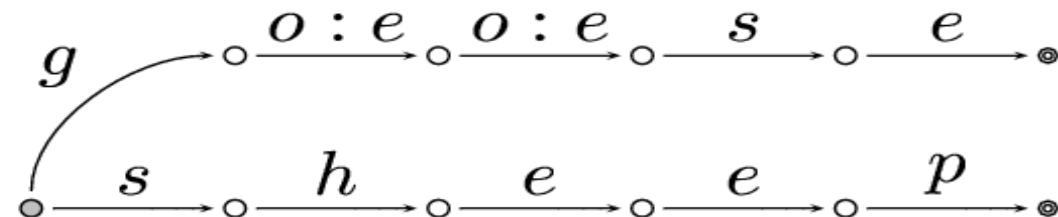
# Το λεξικό του ΜΠΚ

---

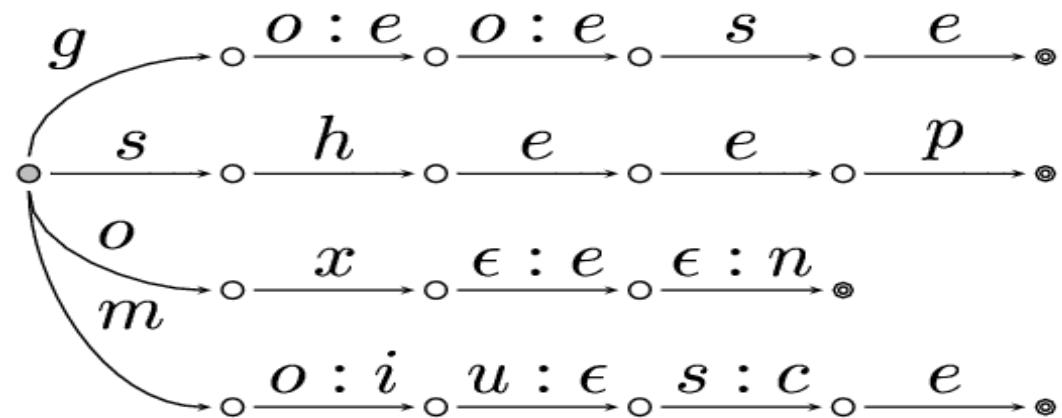
<b>reg-noun</b>	<b>irreg-sg-noun</b>	<b>irreg-pl-noun</b>
fox	goose	g o:e o:e s e
cat	sheep	sheep
dog	mouse	m o:i u:ε s:c e



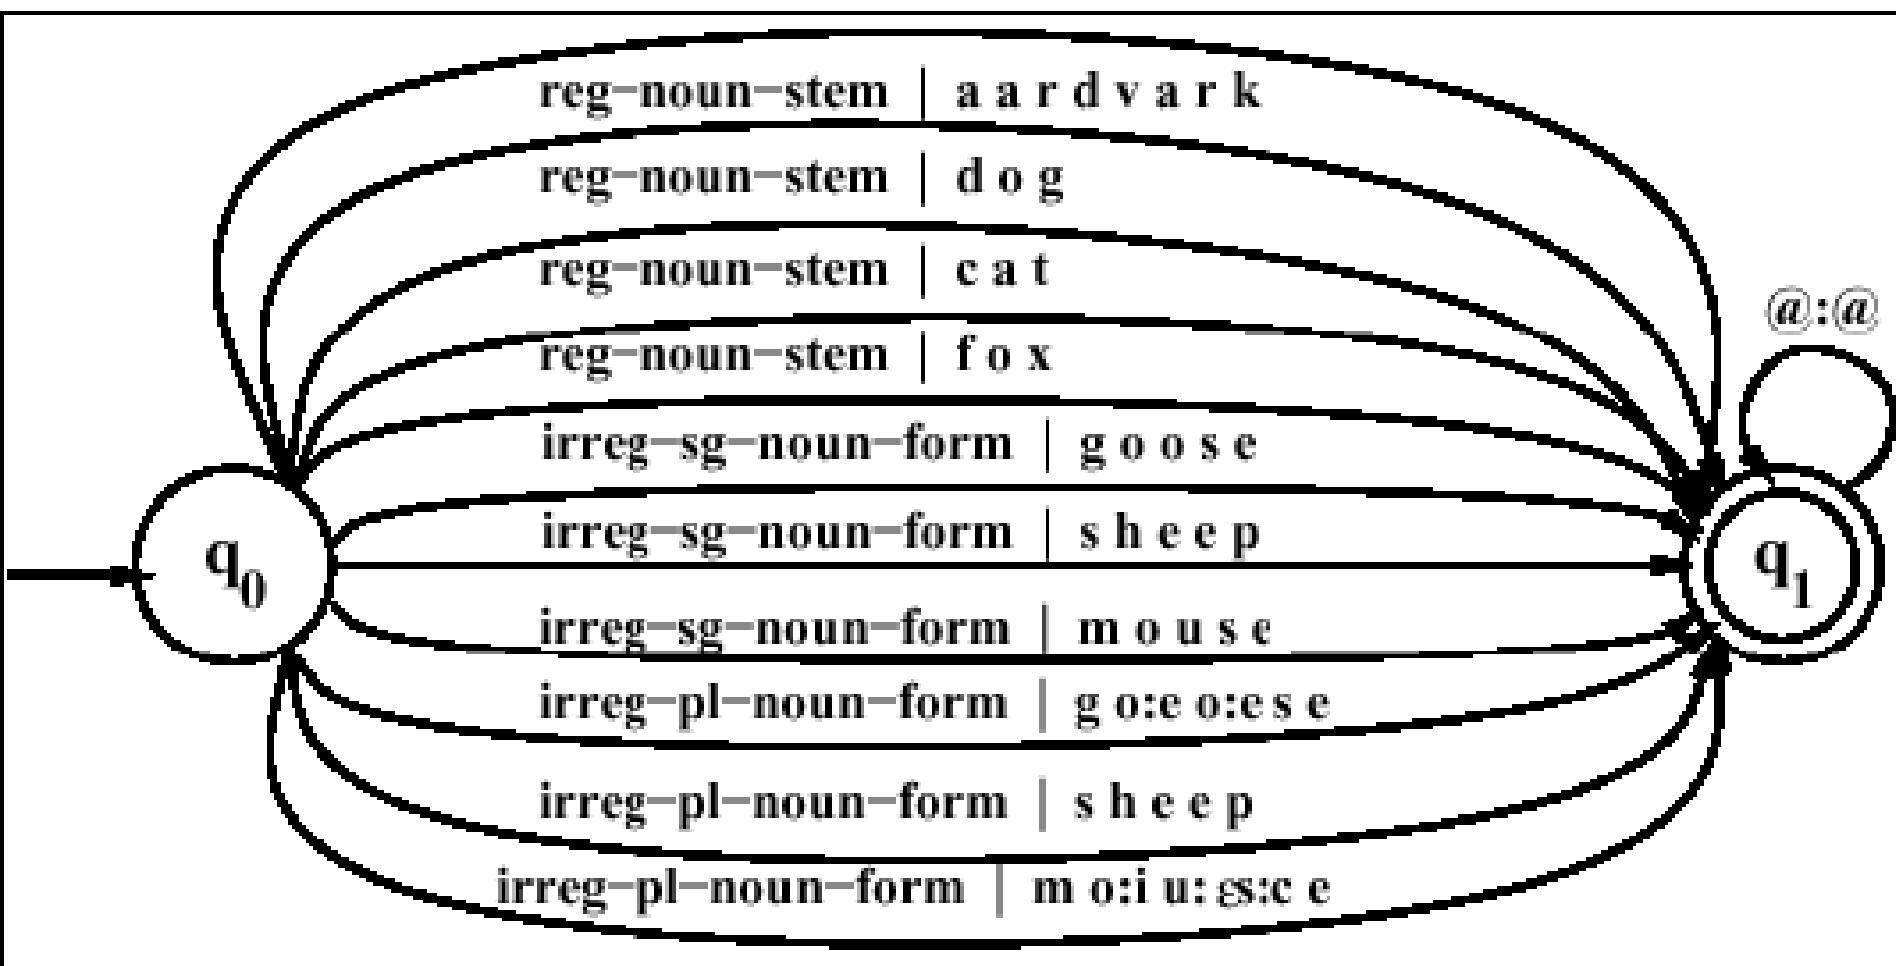
Shorthand notation:



Adding  $\epsilon$ -moves:



# Το λεξικό του ΜΠΚ

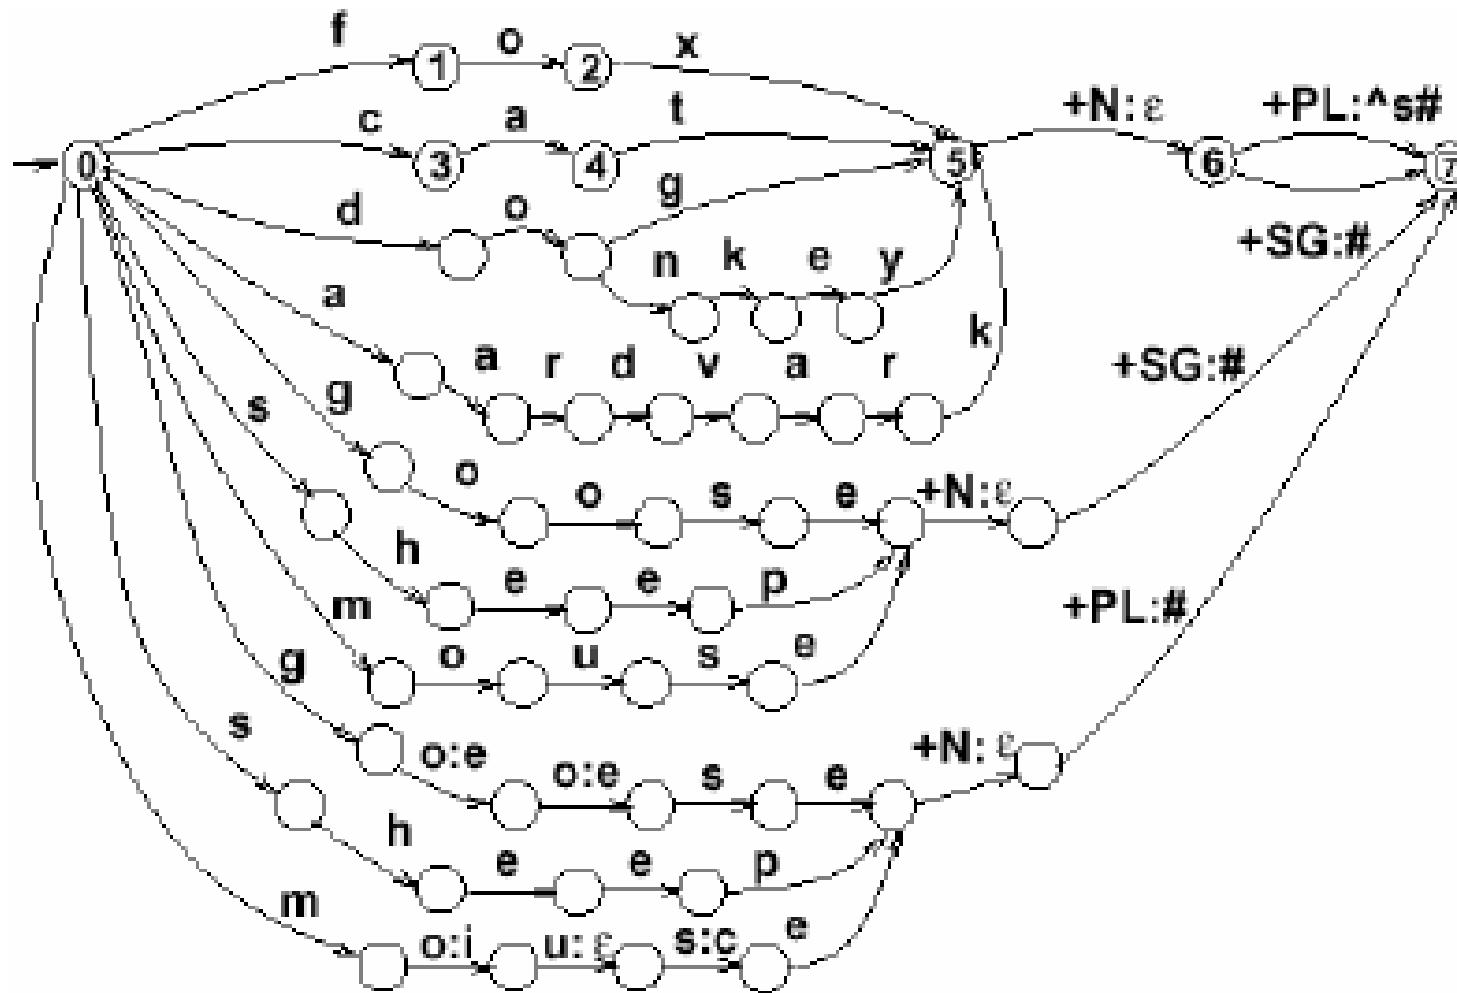


# Συνδυασμός των 2 ΜΠΚ

---

- Οι δύο ΜΠΚ (για το λεξικό και τους μορφολογικούς κανόνες) μπορούν να ενωθούν σειριακά (**cascaded**)
- Η έξοδος του ΜΠΚ για το λεξικό οδηγείται στην είσοδο του ΜΠΚ των μορφολογικών κανόνων
- Με την διαδικασία της **σύνθεσης** (composition) είναι δυνατό από πολλούς ΜΠΚ να δημιουργήσουμε έναν μοναδικό ΜΠΚ δυο ταινιών που να αντιστοιχεί από τη λεξικολογική μορφή στην επιφανειακή μορφή

# Ο συνδυασμένος ΜΠΚ



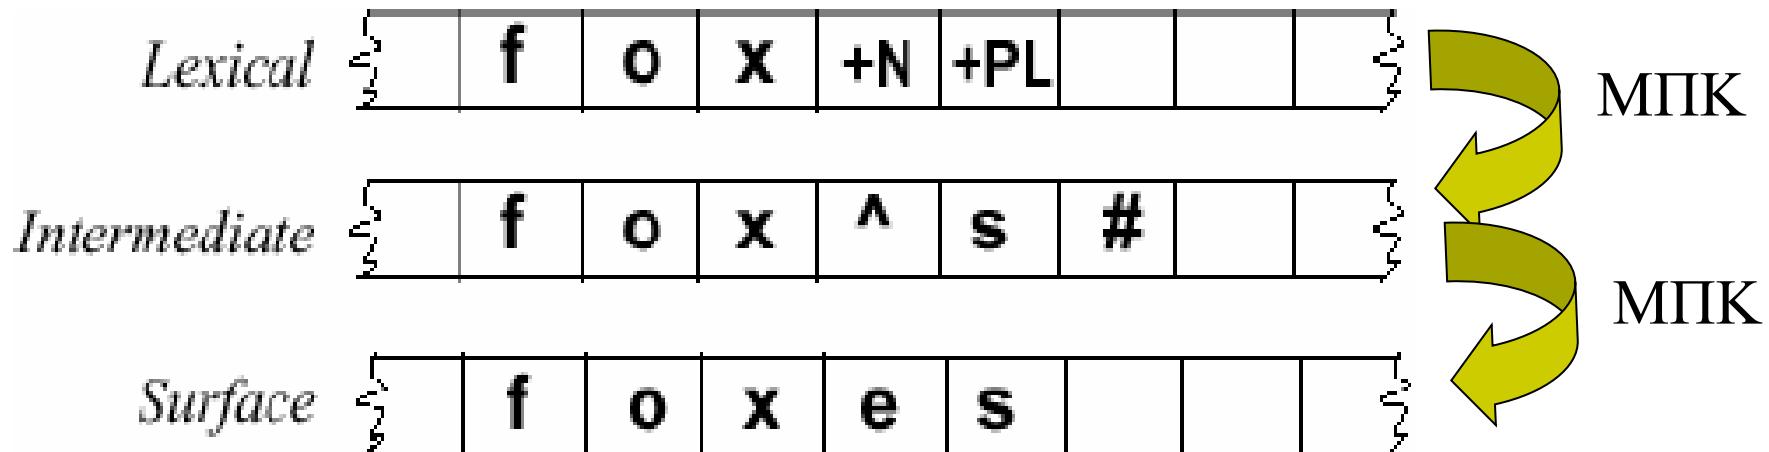
# Ορθογραφικοί κανόνες

---

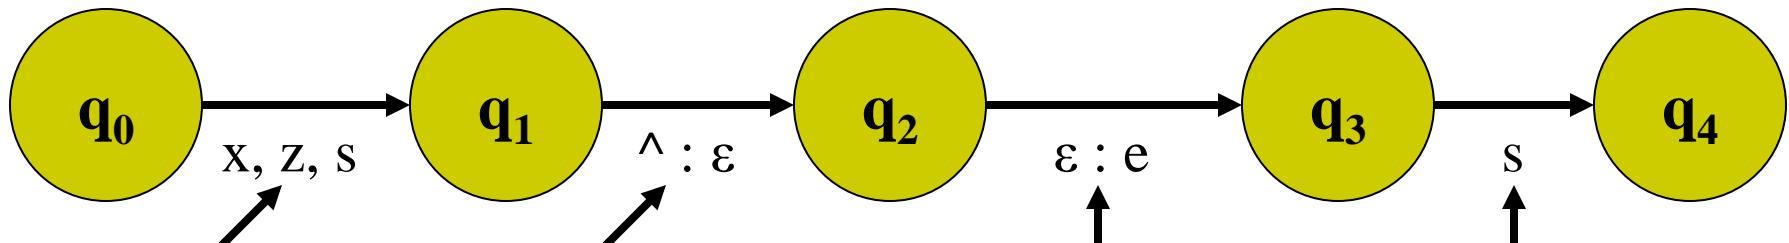
- Το προηγούμενο FST θα αποδεχόταν τη λέξη *foxs* και θα απέρριπτε τη λέξη *foxes*
- Χρειάζεται να χειριστούμε τις αλλαγές που συμβαίνουν συχνά στα όρια των μορφημάτων
- Αυτό γίνεται με τους ορθογραφικούς κανόνες
  - *Π.χ.* εισάγεται ένα *e* μετά τα *-s*, *-z*, *-x*, *-ch*, *-sh* και πριν από το *-s* (*watch/watches*, *ax/axes*)  
α  $\rightarrow$  *b/c\_d* σημαίνει το *a* γίνεται *b* όταν βρίσκεται μεταξύ των *c* και *d*  
 $\varepsilon \rightarrow e/\{x,s,z\}^n s\#$ .
  - *To -y* γίνεται *-ie* πριν το *-s* (*try/tries*, *sky/skies*)

# Ορθογραφικοί κανόνες και ΜΠΚ

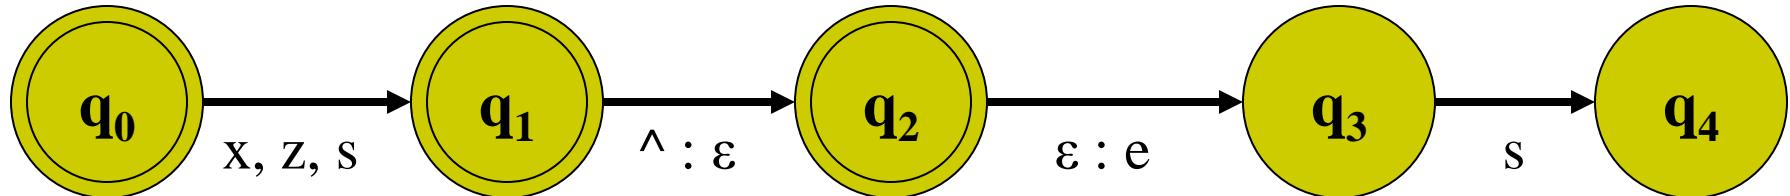
- Ένας ορθογραφικός κανόνας θεωρεί το εξωτερικό (δεύτερο) επίπεδο του προηγούμενου ΜΠΚ (το επίπεδο της συνένωσης των μορφημάτων) σαν ενδιάμεσο (intermediate) επίπεδο.
- Παράγει ένα καινούριο επιφανειακό επίπεδο, το οποίο αναπαριστά μια συνένωση καινούριων μορφημάτων που είναι ορθογραφικά σωστή.



# Δημιουργία του ΜΠΚ για τον προηγούμενο ορθογραφικό κανόνα

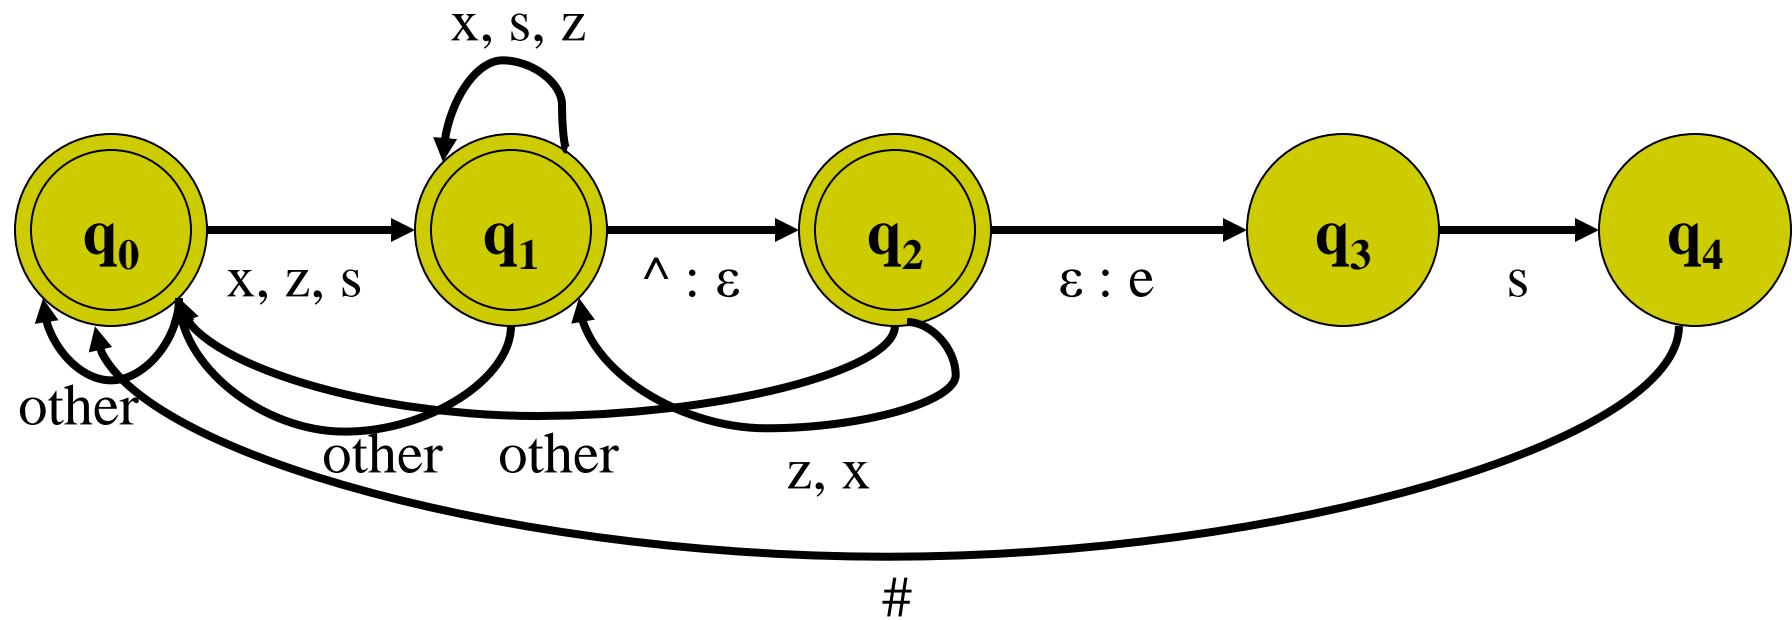


Μόλις μέσα στην λέξη μου φτάσω σε αποτελεί τέλος γράμμα  $x, z$  ή  $s$  Και το γράμμα αυτό μορφήματος, πρέπει να σβηστεί το όριο του μορφήματος Προστίθεται το γράμμα  $e$  Ακολουθεί το γράμμα  $s$



Η  $q_0$  είναι τελική κατάσταση για όλα τα default pairs που είναι άσχετα με τον κανόνα. Η  $q_1$  είναι τελική για τις λέξεις που περιλαμβάνουν  $x, z, s$ . Η  $q_2$  είναι τελική κατάσταση για όσες λέξεις το  $x, z$ , ή  $s$  είναι τέλος μορφήματος.

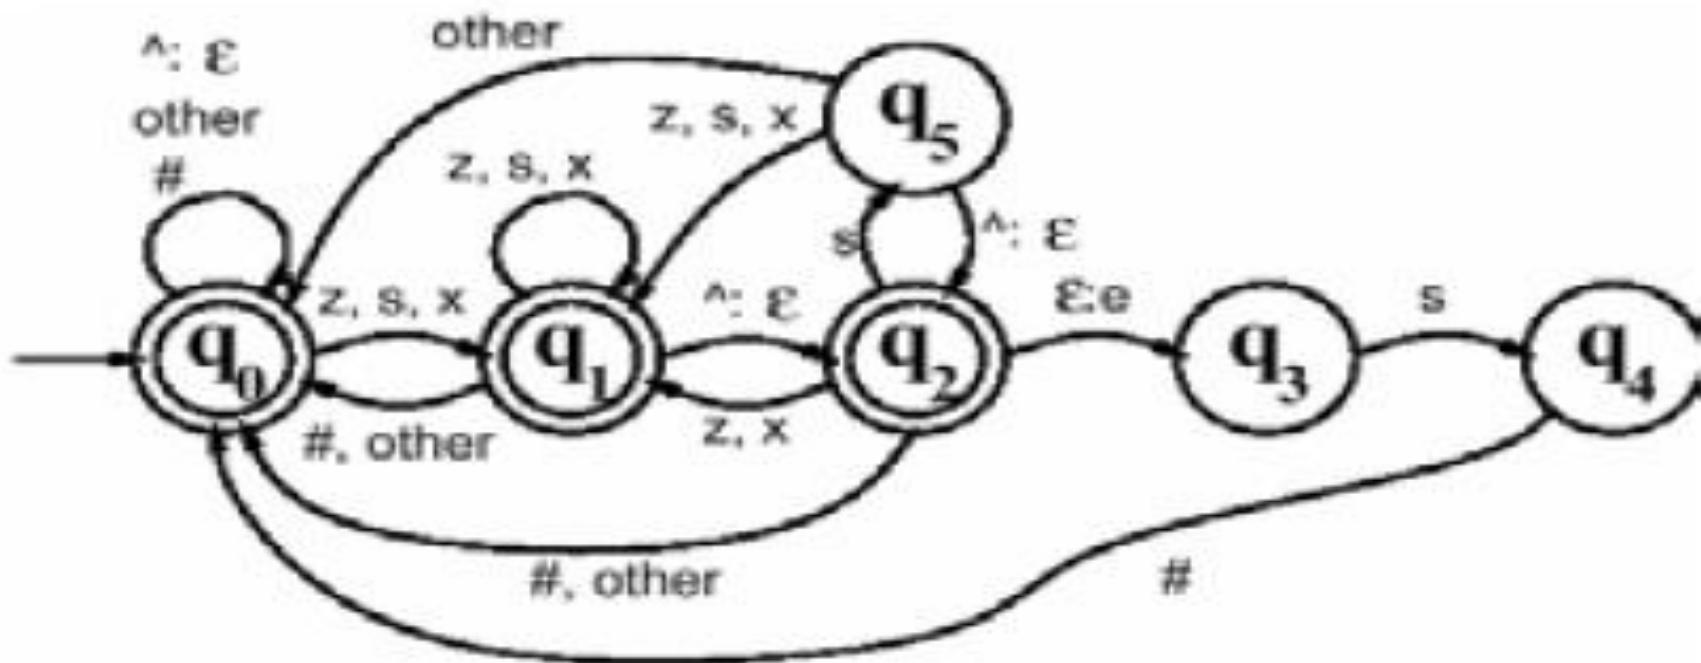
# Δημιουργία του ΜΠΚ για τον προηγούμενο ορθογραφικό κανόνα (συν)



Πρέπει να εξασφαλιστεί η κάλυψη και των υπόλοιπων (άσχετων με τον συγκεκριμένο κανόνα) περιπτώσεων.

# Ορθογραφικοί κανόνες και ΜΠΚ

Πρέπει να προστεθεί μια ακόμα κατάσταση ( $\eta q_5$ ), η οποία θα εξασφαλίζει ότι σε κάθε περίπτωση που θα ικανοποιείται το πριν και μετά περιβάλλον, πάντα θα προστίθεται το ε. Έτσι από την  $q_2$ , (δηλ. πριν προστεθεί το ε) αν έρθει s πάω στην  $q_5$ , και από εκεί δεν μπορεί να έχω τέλος λέξης (#).



# Πίνακας Μετάβασης

---

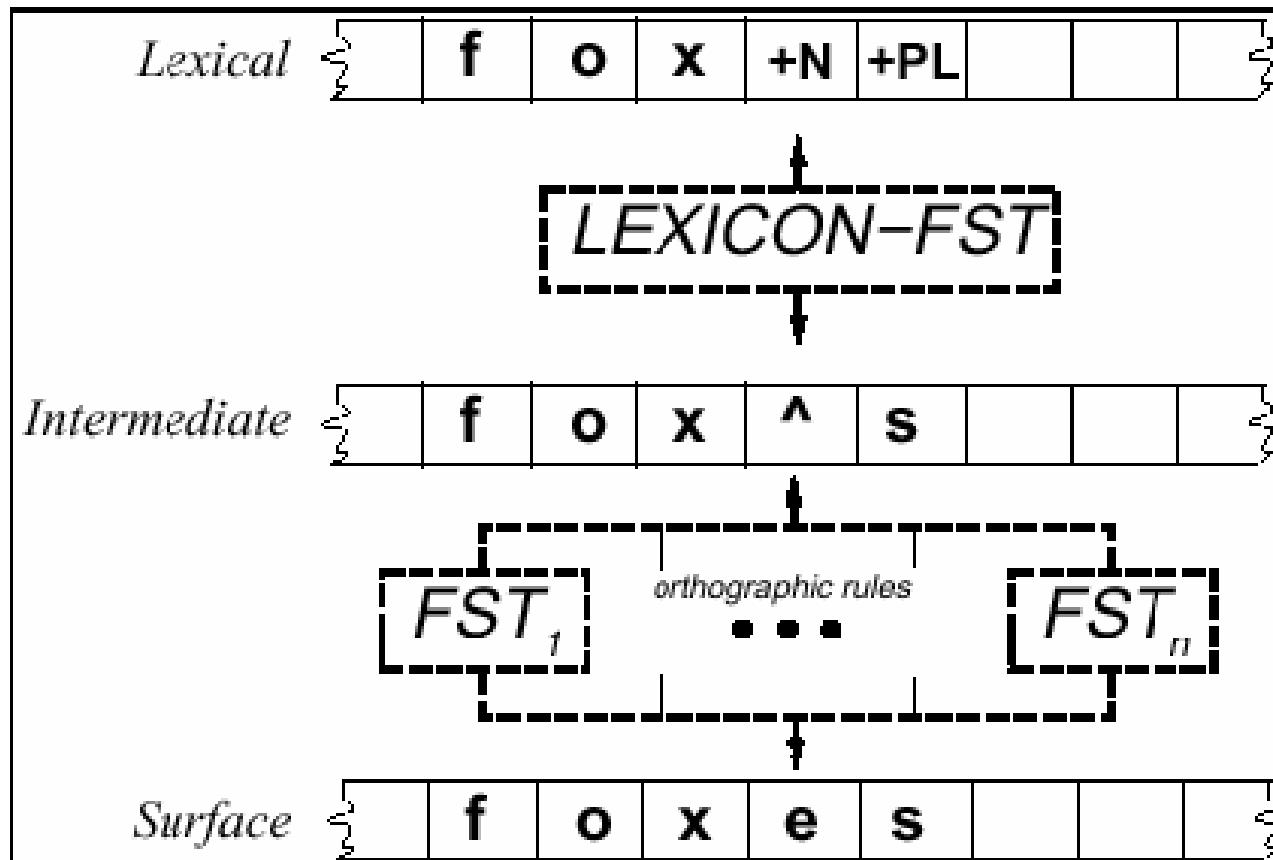
State/ Input	s:s	x:x	z:z	$\wedge:\varepsilon$	$\varepsilon:e$	#	other
q0:	1	1	1	0	-	0	0
q1:	1	1	1	2	-	0	0
q2:	5	1	1	0	3	0	0
q3	4	-	-	-	-	-	-
q4	-	-	-	-	-	0	-
q5	1	1	1	2	-	-	0

# Συνδυασμός των ΜΠΚ του Λεξικού και των Κανόνων

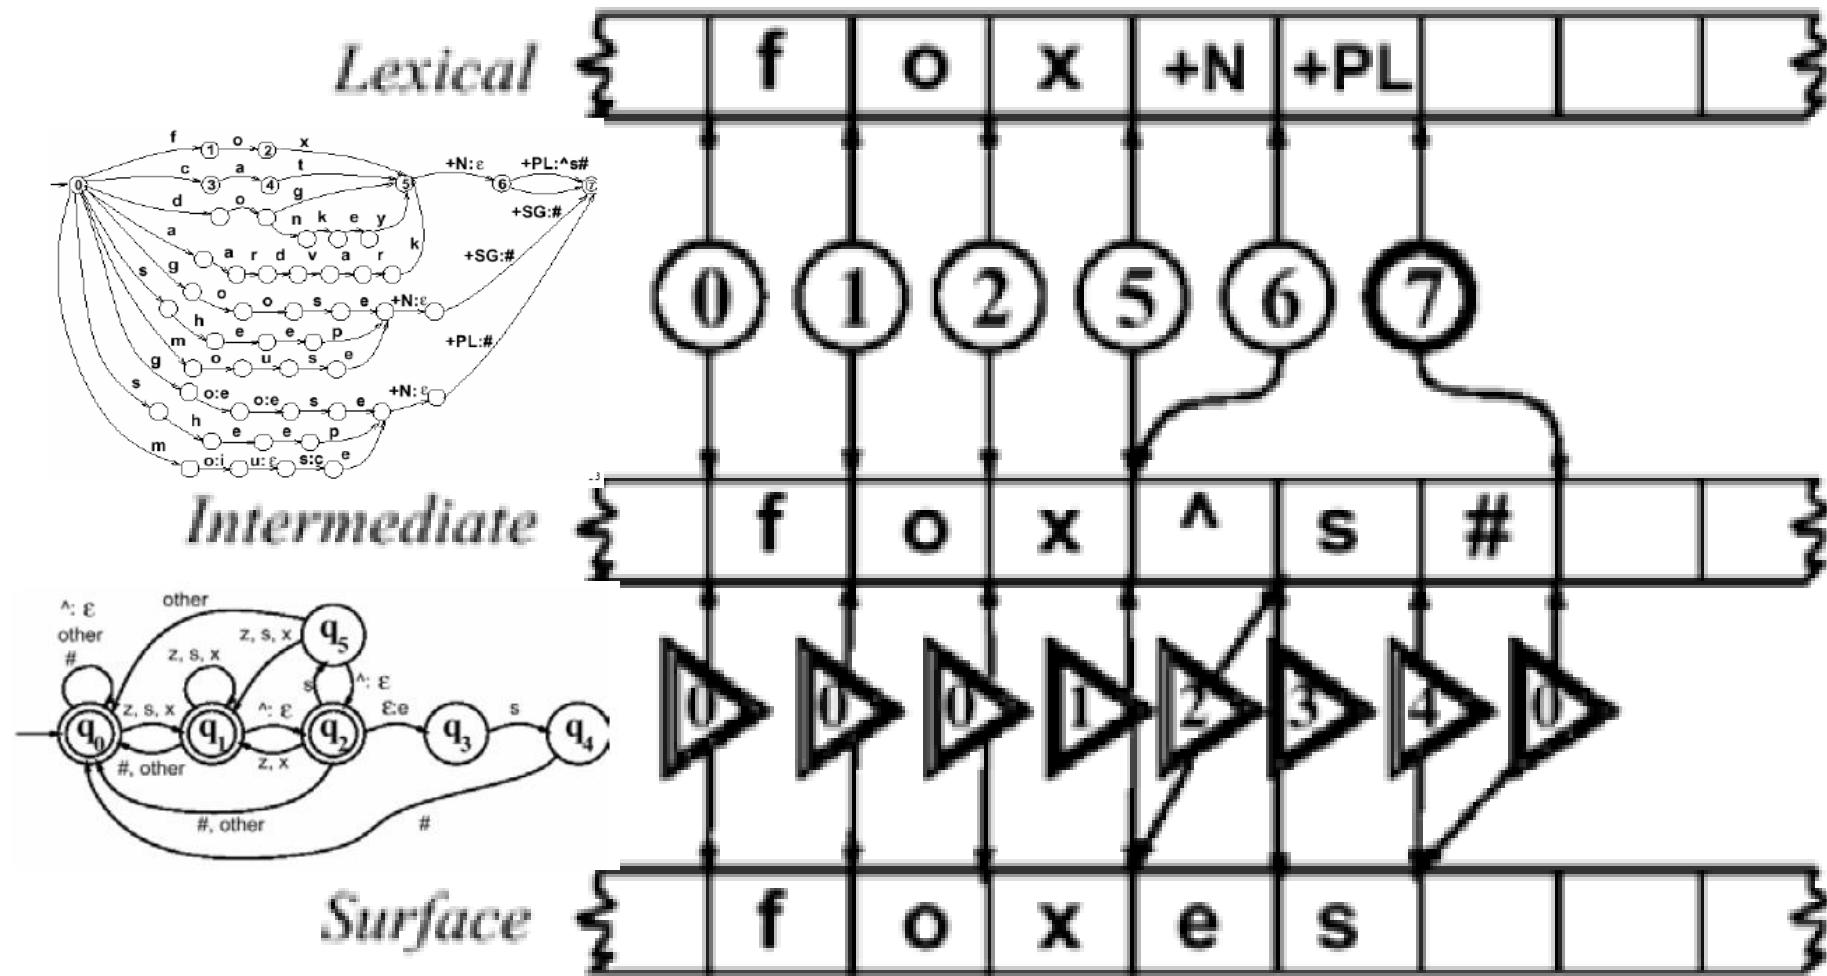
---

- Αρχικά ο ΜΠΚ λεξικού αντιστοιχίζει το λεξιλογικό επίπεδο στο ενδιάμεσο επίπεδο (απλή συνένωση μορφημάτων)
- Ένας αριθμός ΜΠΚ κανόνων τρέχουν παράλληλα (ή ως cascade) και αντιστοιχίζουν το ενδιάμεσο επίπεδο στο επιφανειακό επίπεδο
- Ο ΜΠΚ λεξικού και οι ΜΠΚ των ορθογραφικών κανόνων σχηματίζουν ένα cascade.
  - top-down (generation)
  - bottom-up (parsing)

# Συνδυασμός των ΜΠΚ του Λεξικού και των Κανόνων



# Συνδυασμός των ΜΠΚ του Λεξικού και των Κανόνων



# Ανάλυση-Παραγωγή

---

- Η ανάλυση (parsing) είναι πιο περίπλοκη από την παραγωγή (generation) λόγω της ασάφειας.
  - Π.χ. η λέξη *foxes* μπορεί να αναλυθεί ως *fox+V+3SG* (*foxes*: *κοροϊδεύει*) και *fox+N+PL* (*foxes*: *αλεπούδες*)
- Η αποσαφήνιση (disambiguation) δεν μπορεί να επιλυθεί χωρίς τα συμφραζόμενα
  - Ο ΜΠΚ πρέπει να δημιουργήσει και τις δύο αναλύσεις
- Επίσης, προκαλούνται ασάφειες εξαιτίας του ε ή λόγω πολλαπλών πιθανών μονοπατιών

# Two-Level Morphology Software

---

- PC-KIMMO
  - <http://www.sil.org/pckimmo/>
- Μορφολογικές περιγραφές για τα Αγγλικά και άλλες γλώσσες είναι διαθέσιμες

# Stemming

---

- Stemming ονομάζεται η εύρεση της ρίζας μιας λέξης
  - marsupials -> marsupial
  - trying -> try
- Σε πολλές εφαρμογές (ιδίως ανάκτησης πληροφορίας) δεν είναι απαραίτητη πλήρης μορφολογική ανάλυση (που απαιτεί πολύπλοκους κανόνες και λεξικά)
- Απλά αρκεί να βρεθεί ότι δύο λέξεις έχουν την ίδια ρίζα.

# Porter Stemmer (1980)

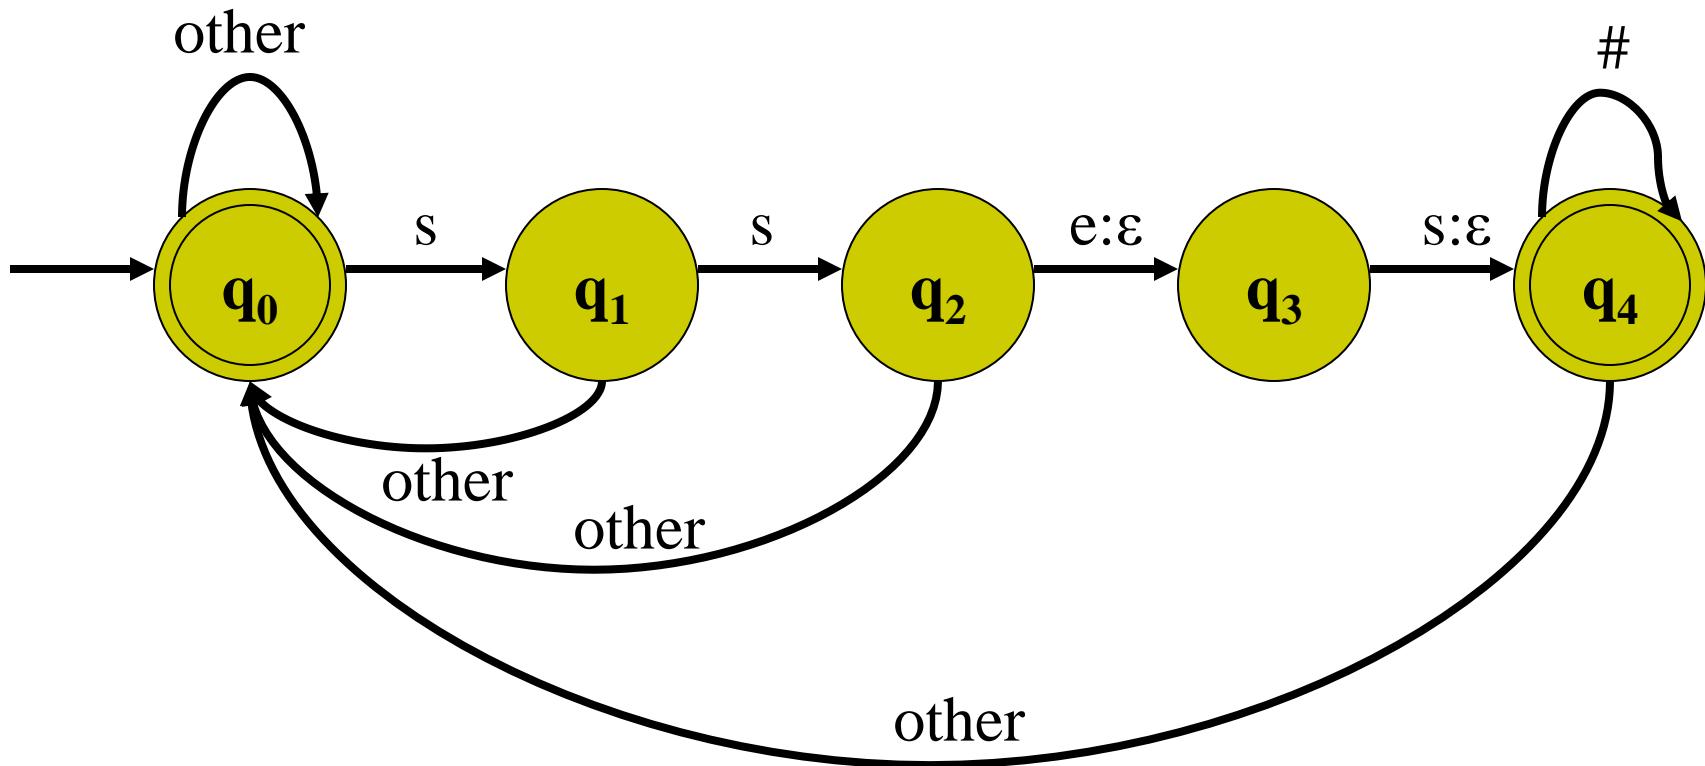
---

- <http://www.tartarus.org/~martin/PorterStemmer/>
- Πρόκειται για ευρέως διαδεδομένο stemmer
- Βασίζεται σε έναν αριθμό απλών κανόνων
  - ATIONAL -> ATE (relational -> relate)
  - ING-> ε (knowing -> know)
- Οι stemmers δεν έχουν απόλυτη ακρίβεια
  - Λάθη του Porter stemmer:
    - organization -> organ
    - policy -> police
  - Περιπτώσεις που ο Porter stemmer δεν καλύπτει:
    - matrices -> matrix
    - explain -> explanation

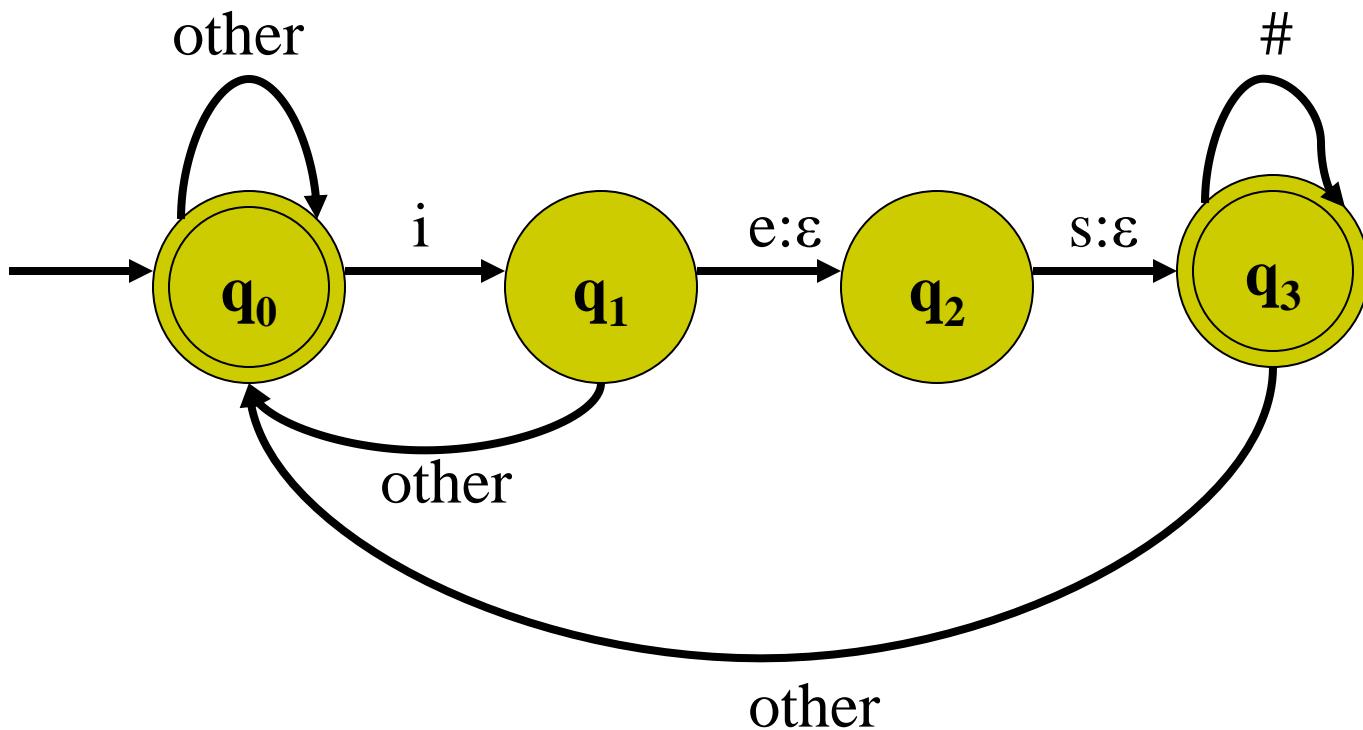
# Άσκηση

- Στον Porter Stemmer εφαρμόζονται οι ακόλουθοι κανόνες για την λημματοποίηση μιας λέξης:
  - Xses -> Xss
    - caresses -> caress
  - Xies -> Xi    X: οποιαδήποτε ακολουθία χαρ/ρων
  - ponies -> poni
  - XSS -> XSS
  - caress -> caress    Να υλοποιηθούν οι κανόνες αυτοί με ΜΠΚ.
  - Xs -> X
    - cats -> cat
  - Xeed -> Xee , (|X|>1)
    - feed -> fee, agreed -> agree
  - Xed -> X , (X contains vowel)
    - plastered -> plaster, bled -> bled
  - Xing -> X , (X contains vowel)
    - motoring -> motor, sing -> sing

# 1ος κανόνας: Xsses -> XSS

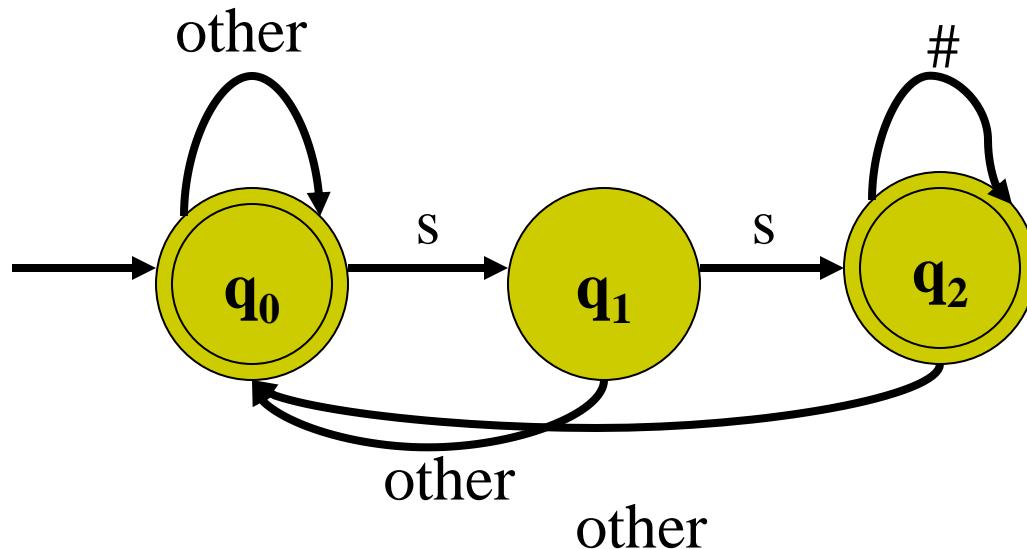


## 2ος κανόνας: Xies -> Xi



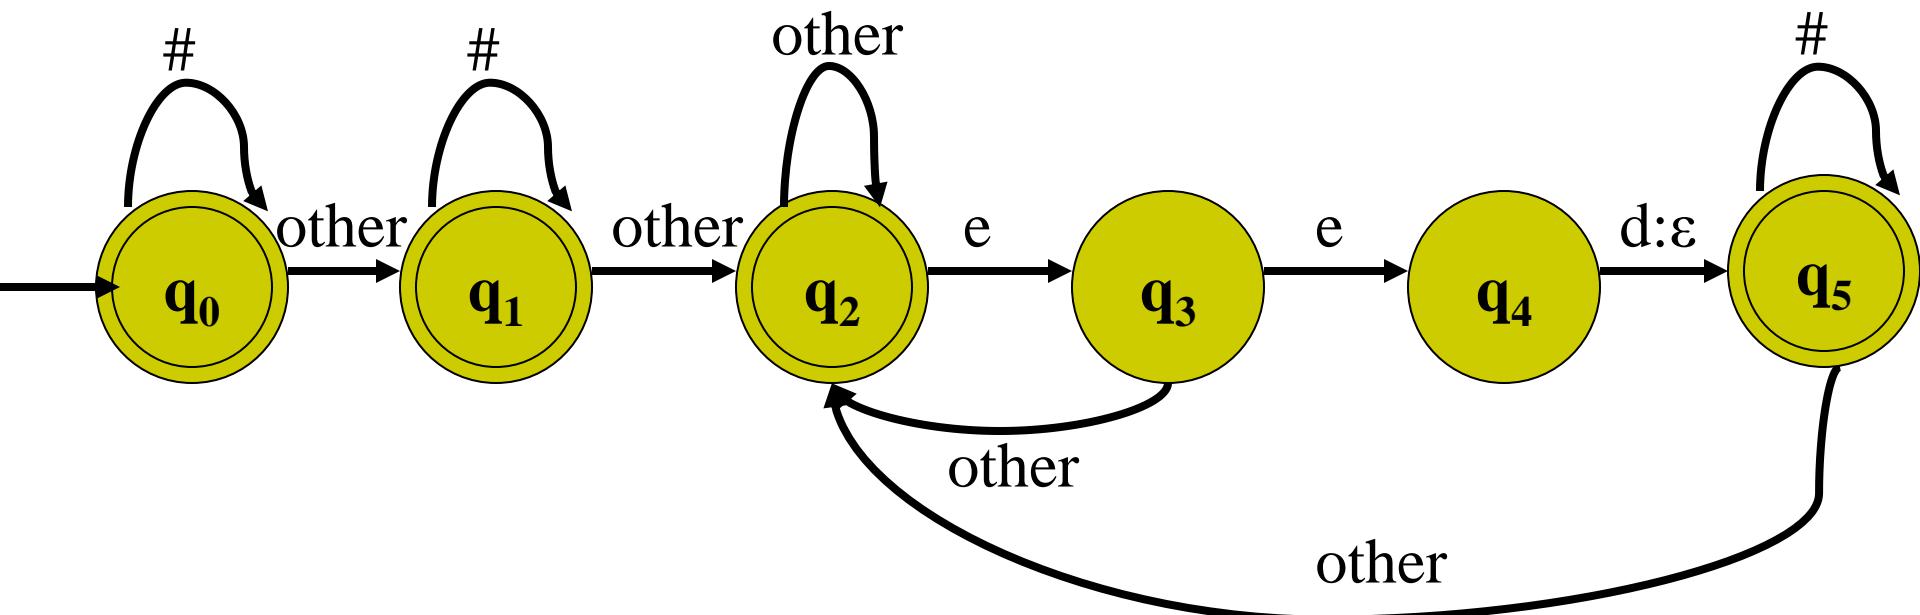
# 3ος κανόνας: XSS -> XSS

---

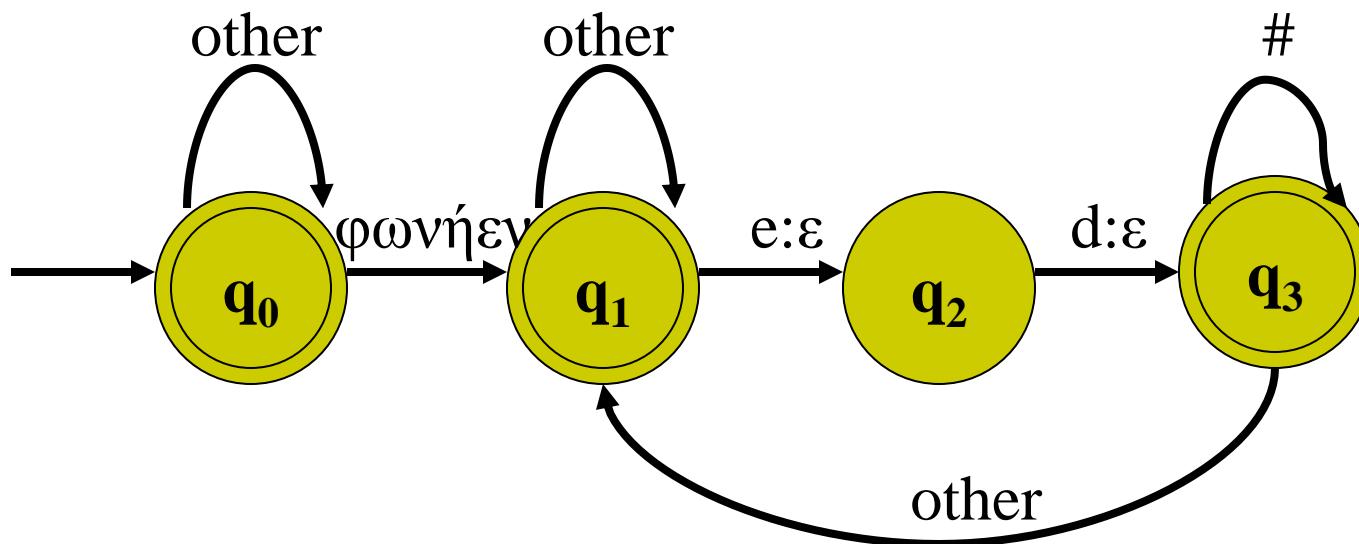


## 4ος κανόνας: Xeed -> Xee, $|X| > 1$

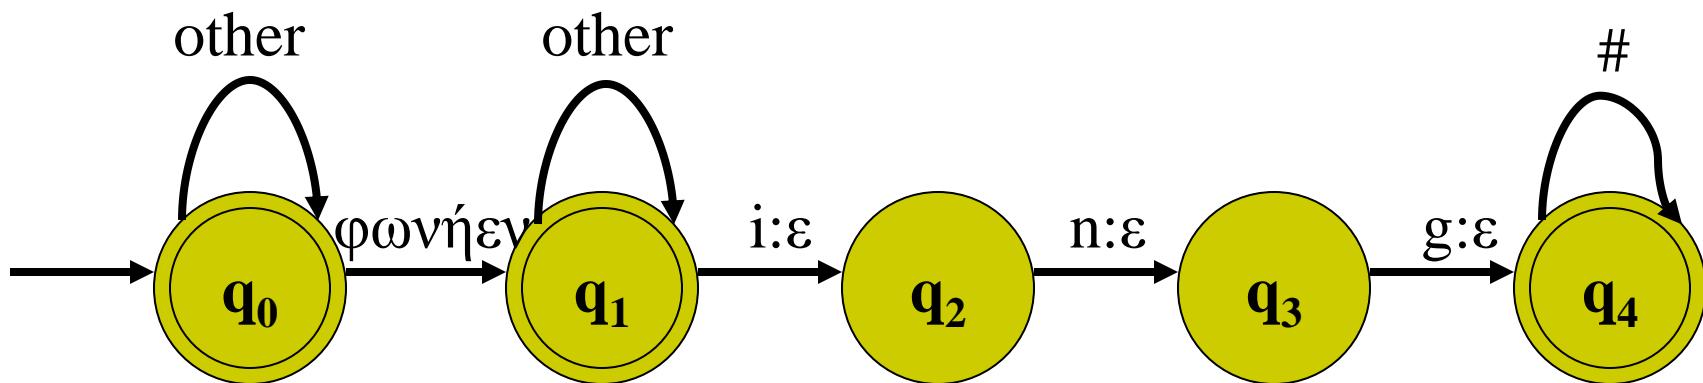
---



5ος κανόνας:  $Xed \rightarrow X$ , (το  $X$  περιέχει φωνήεν)



6ος κανόνας: Xing -> X, (το X περιέχει φωνήεν)



# Ο αλγόριθμος Soundex

---

- Ο αλγόριθμος Soundex μετατρέπει κύρια ονόματα σε κωδικούς:
  - Jurafsky -> J612
  - Jarofski -> J612
  - Clinton -> C453
  - Bush -> B200

# Ο αλγόριθμος

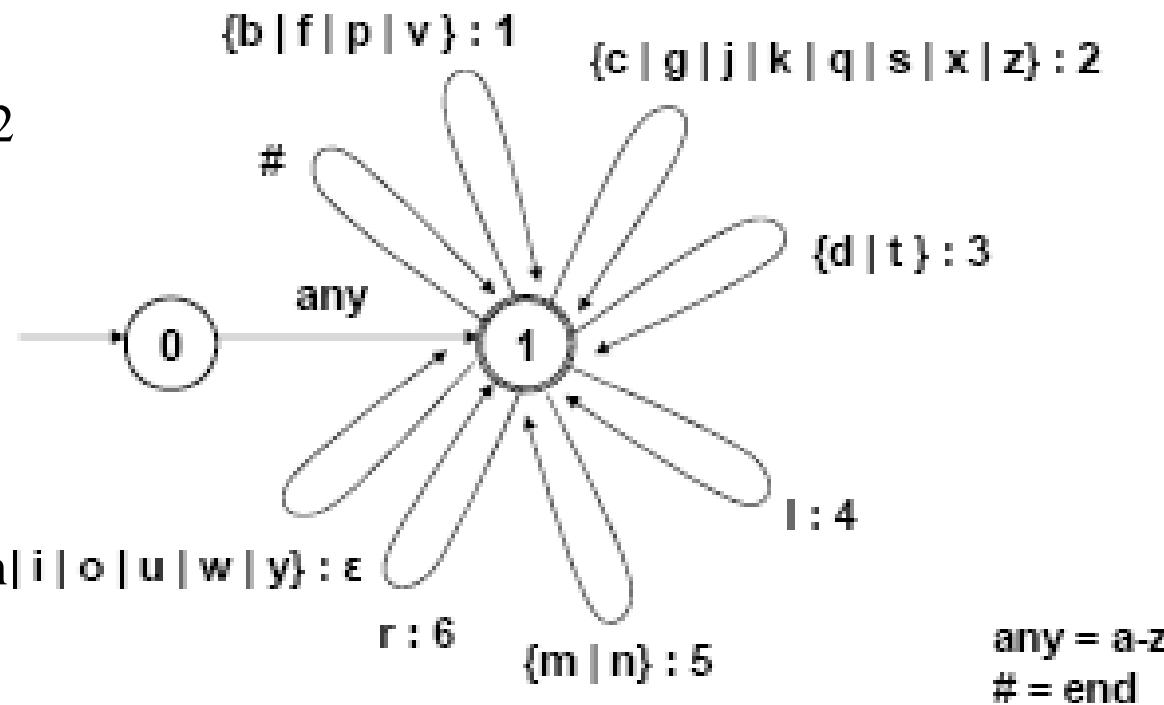
---

- Κράτησε το πρώτο γράμμα του ονόματος και αγνόησε όλες τις εμφανίσεις των μη-αρχικών a, e, h, i, o, u, w, y
- Αντικατέστησε τα υπόλοιπα γράμματα με τους ακόλουθους αριθμούς:
  - b, f, p, v -> 1
  - c,g, j, k, q, s, x, z -> 2
  - d,t -> 3
  - l -> 4
  - m, n -> 5
  - r -> 6
- Αντικατέστησε τυχόν ακολουθίες ίδιων αριθμών με ένα απλό αριθμό (666->6)
- Μετέτρεψε στη μορφή ‘Γράμμα Ψηφίο Ψηφίο Ψηφίο’ αγνοώντας τα ψηφία μετά το τρίτο (αν χρειάζεται) ή προσθέτοντας μηδενικά στο τέλος (αν χρειάζεται)

# Υλοποίηση ΜΠΚ (1<sup>ο</sup> βήμα)

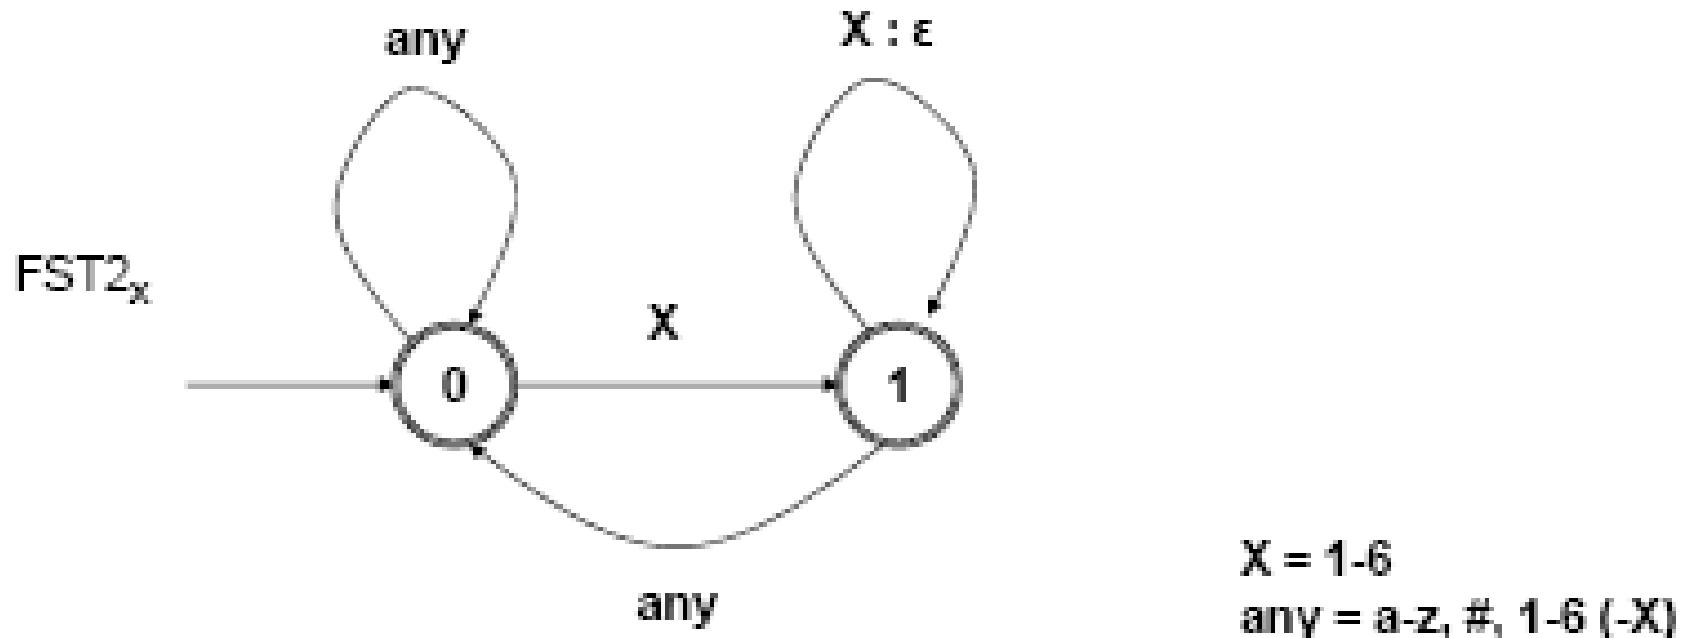
- Κράτησε το πρώτο γράμμα του ονόματος και αγνόησε όλες τις εμφανίσεις των μη-αρχικών a, e, h, i, o, u, w, y
- Αντικατέστησε τα υπόλοιπα γράμματα με τους ακόλουθους αριθμούς:

- b, f, p, v -> 1
- c,g, j, k, q, s, x, z -> 2
- d,t -> 3
- l -> 4
- m, n -> 5
- r -> 6



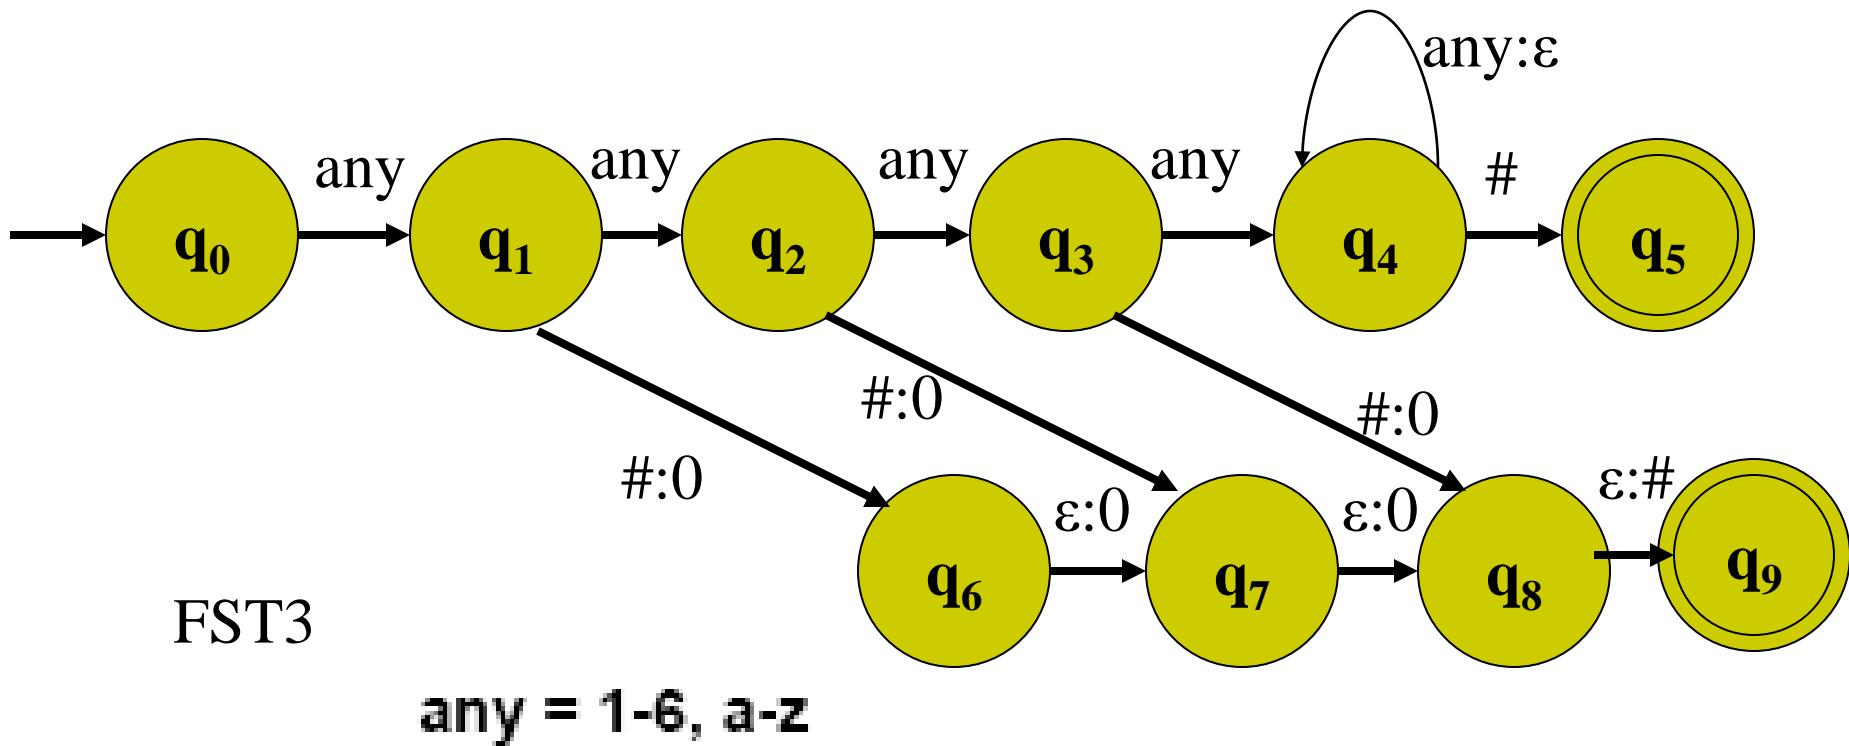
# Υλοποίηση ΜΠΚ (2<sup>o</sup> βήμα)

- Αντικατέστησε τυχόν ακολουθίες ίδιων αριθμών με έναν απλό αριθμό (666->6)

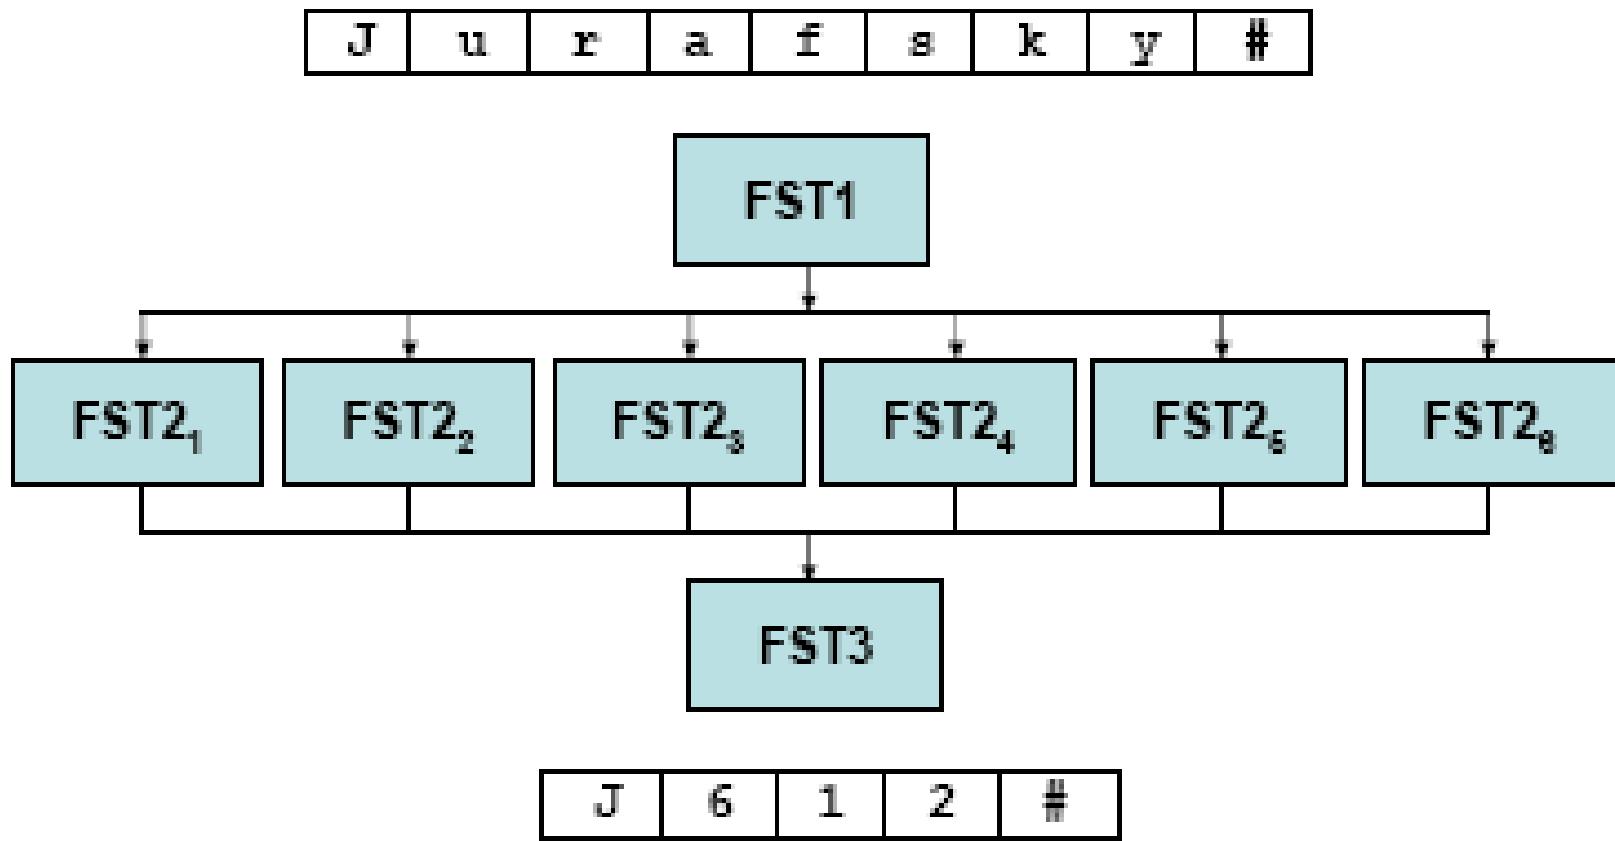


# Υλοποίηση ΜΠΚ (3<sup>ο</sup> βήμα)

- Μετέτρεψε στη μορφή ‘Γράμμα Ψηφίο Ψηφίο Ψηφίο’ αγνοώντας τα ψηφία μετά το τρίτο (αν χρειάζεται) ή προσθέτοντας μηδενικά στο τέλος (αν χρειάζεται)



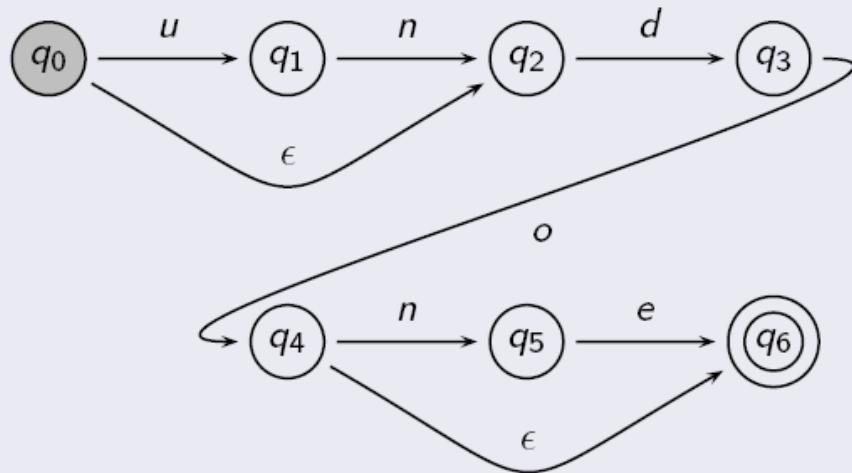
# Σχεδιασμός



# Άσκηση για ΑΠΚ

## Example: Automata with $\epsilon$ -moves

The language accepted by the following automaton is  $\{do, \text{ undo}, \text{ done}, \text{ undone}\}$ :



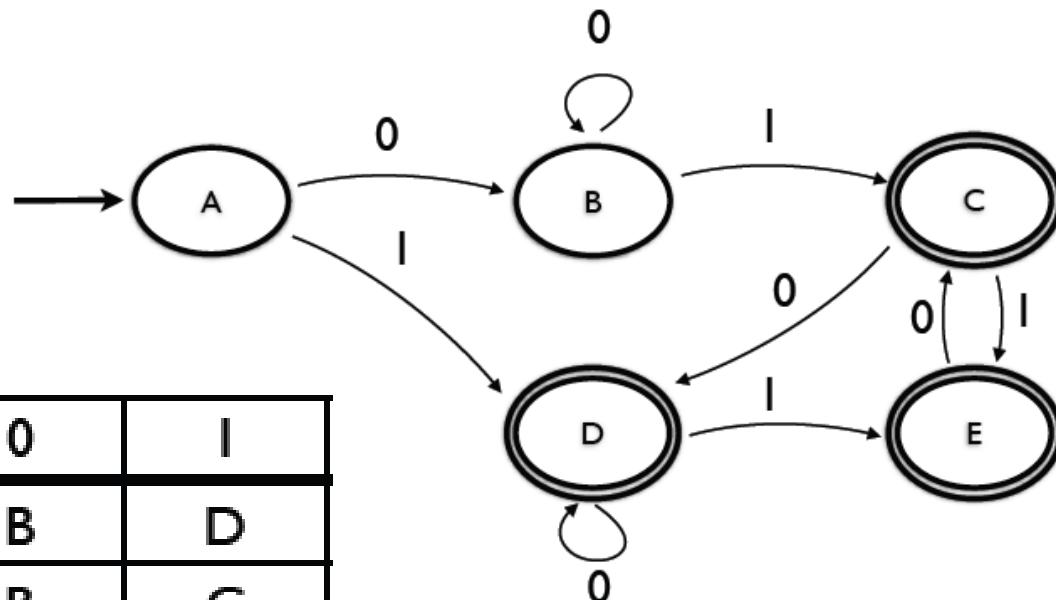
# Ασκηση

Σχεδιάστε το παρακάτω ΑΠΚ

---

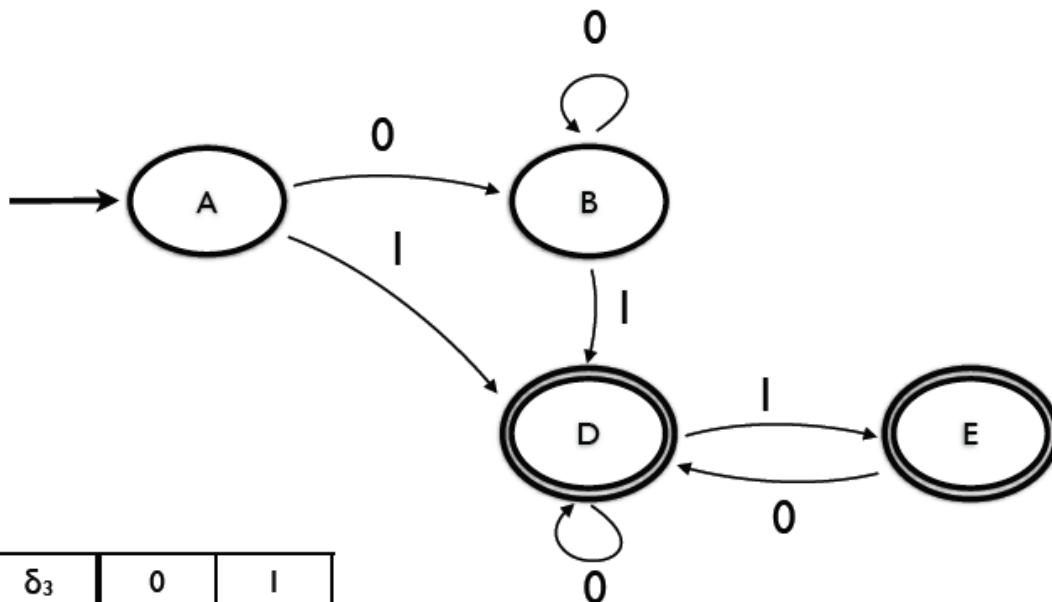
$\delta_3$	0	1
A	B	D
B	B	C
C	D	E
D	D	E
E	C	

# Λύση (1/3)



Οι καταστάσεις C και D είναι  
ισοδύναμες

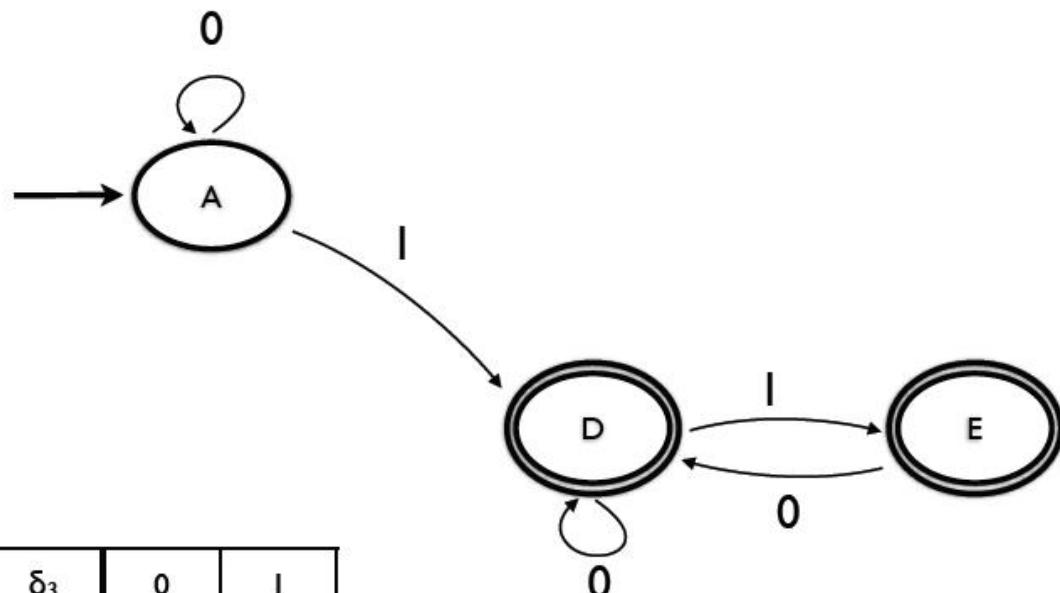
# Λύση (2/3)



$\delta_3$	0	I
A	B	D
B	B	D
D	D	E
E	D	

We can thus remove C  
and redirect all its  
incoming edges to D

# Λύση (3/3)



$\delta_3$	0	I
A	A	D
D	D	E
E	D	

And we're done!