

ΜΥΕ003-ΠΛΕ70: Ανάκτηση Πληροφορίας

Διδάσκουσα: Ευαγγελία Πιτουρά

Κεφάλαιο 3: Δομές για Λεξικά. Ανάκτηση Ανεκτική στα Σφάλματα.

Τι θα δούμε σήμερα;

- Δομές δεδομένων για λεξικά
- Ανάκτηση ανεκτική (tolerant) σε σφάλματα
 - Ερωτήματα με wild-card («χαρακτήρων μπαλαντέρ»)*
 - Ορθογραφικά λάθη
 - Απόσταση μεταξύ όρων
 - Φωνητική διόρθωση

Δομές Δεδομένων για Λεξικά

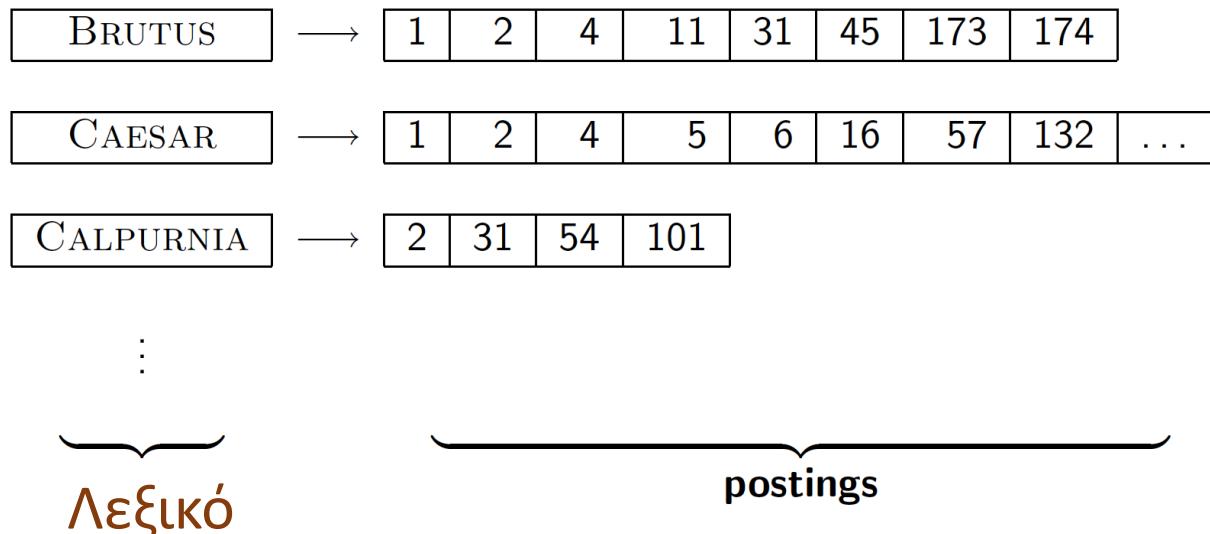
Λεξιλόγιο (vocabulary): το σύνολο των όρων

Λεξικό (dictionary): μια δομή για την αποθήκευση του λεξιλογίου

Πως αποθηκεύουμε ένα λεξικό (στη μνήμη) αποδοτικά;

Δομές Δεδομένων για Λεξικά

- Το λεξικό περιέχει: το λεξιλόγιο όρων (*λήμμα*), για κάθε όρο: τη συχνότητα εγγράφου (document frequency) και δείκτη στη λίστα καταχωρήσεων
- Σε κάθε ερώτημα, αναζήτηση στο λεξικό αν υπάρχει ο όρος και σε ποια έγγραφα



Ποια δομή δεδομένων είναι κατάλληλη;

Μια απλοϊκή λύση

- array of struct:

term	document frequency	pointer to postings list
a	656,265	→
aachen	65	→
...
zulu	221	→

char[20]	int	Postings *
20 bytes	4/8 bytes	4/8 bytes

- Πως αναζητούμε έναν όρο (κλειδί, key) στο λεξικό γρήγορα κατά την εκτέλεση του ερωτήματος;

Δομές Δεδομένων για το Λεξικό

- Δυο βασικές επιλογές:
 - Πίνακες Κατακερματισμού (Hashtables)
 - Δέντρα (Trees)
- Μερικά συστήματα ανάκτησης πληροφορίας χρησιμοποιούν πίνακες κατακερματισμού άλλα δέντρα

Δομές Δεδομένων για Λεξικά

Κριτήρια για την επιλογή δομής:

(ποιες λειτουργίες, workload, μέγεθος)

- Αποδοτική αναζήτηση ενός όρου (κλειδιού) στο λεξικό.
- Σχετικές συχνότητες προσπέλασης των κλειδιών (πιο γρήγορα οι συχνοί όροι;)
- Είναι στατικό ή έχουμε συχνά εισαγωγές/διαγραφές όρων ή και τροποποιήσεις; Μόνο εισαγωγές (insert only – append only)
- Πόσοι είναι οι όροι

Πίνακες Κατακερματισμού

Κάθε όρος του λεξιλογίου κατακερματίζεται σε έναν ακέραιο

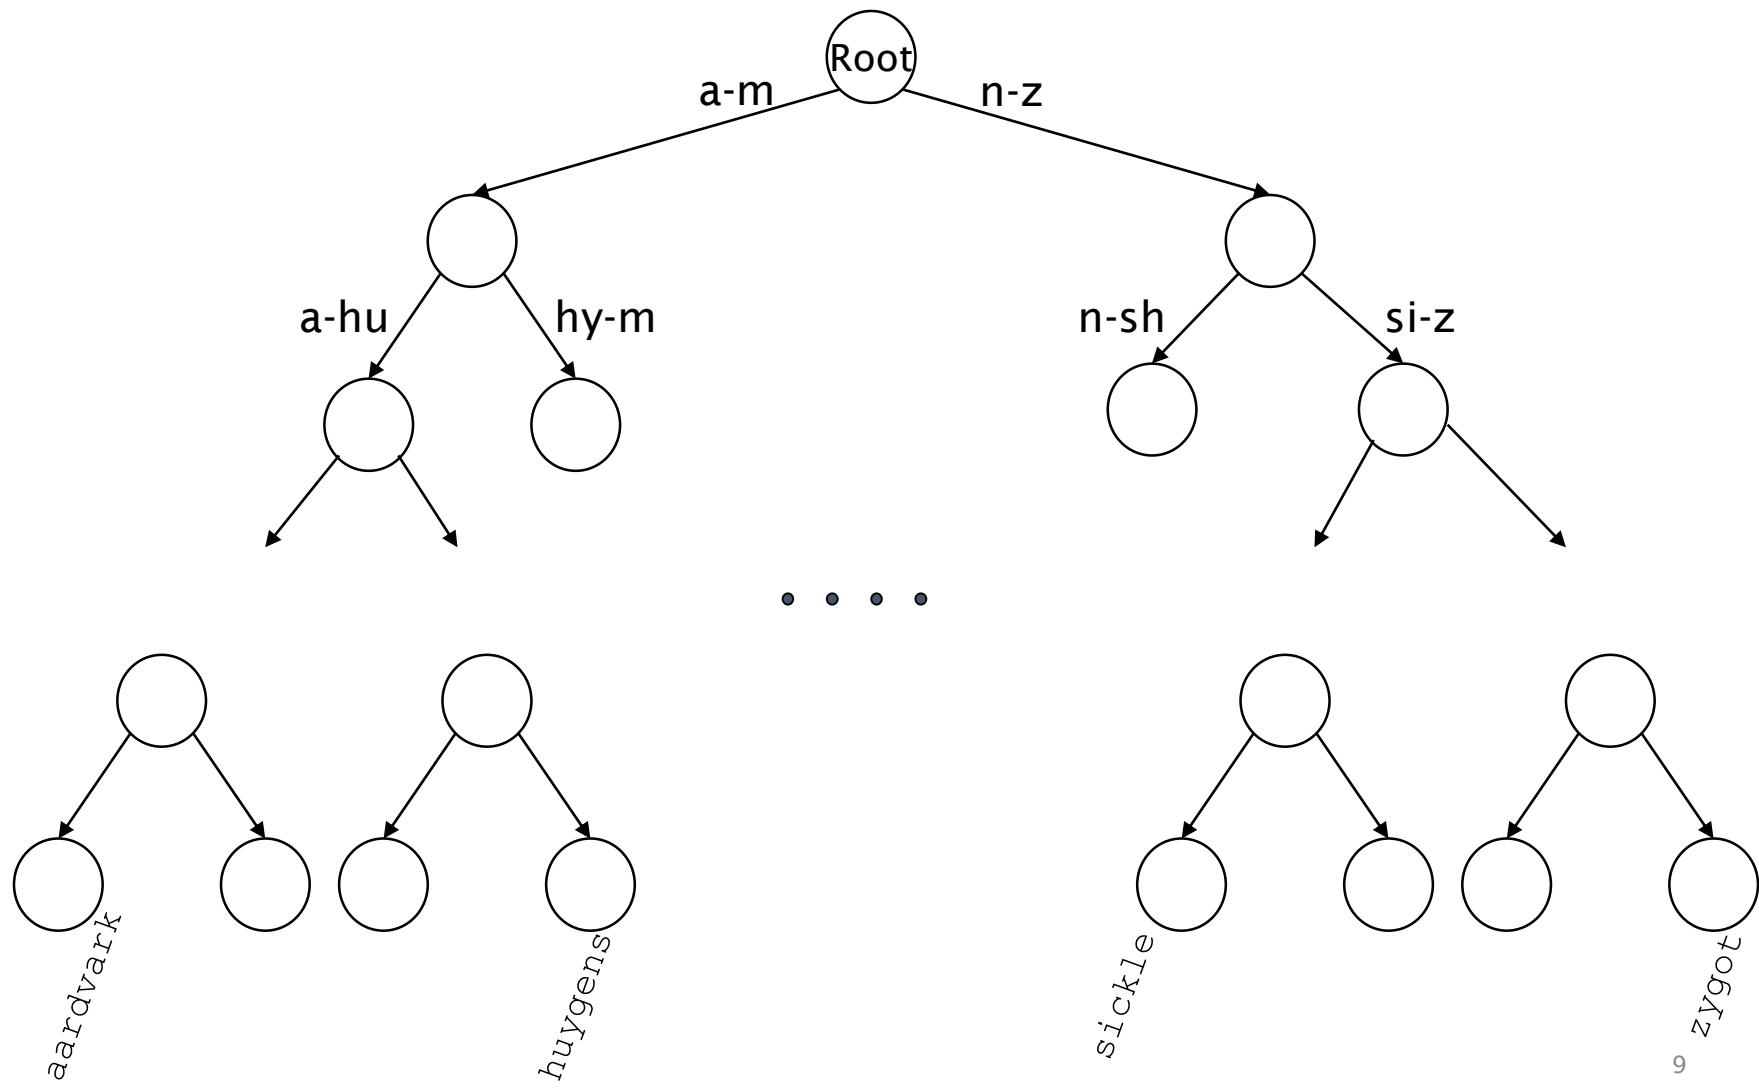
+

- Η αναζήτηση είναι πιο γρήγορη από ένα δέντρο: $O(1)$

- :

- Δεν υπάρχει εύκολος τρόπος να βρεθούν μικρές παραλλαγές ενός όρου
 - judgment/judgement, *resume* vs. *résumé*
- Μη δυνατή η προθεματική αναζήτηση [ανεκτική ανάκληση]
- Αν το λεξιλόγιο μεγαλώνει συνεχώς, ανάγκη για να γίνει κατακερματισμός από την αρχή

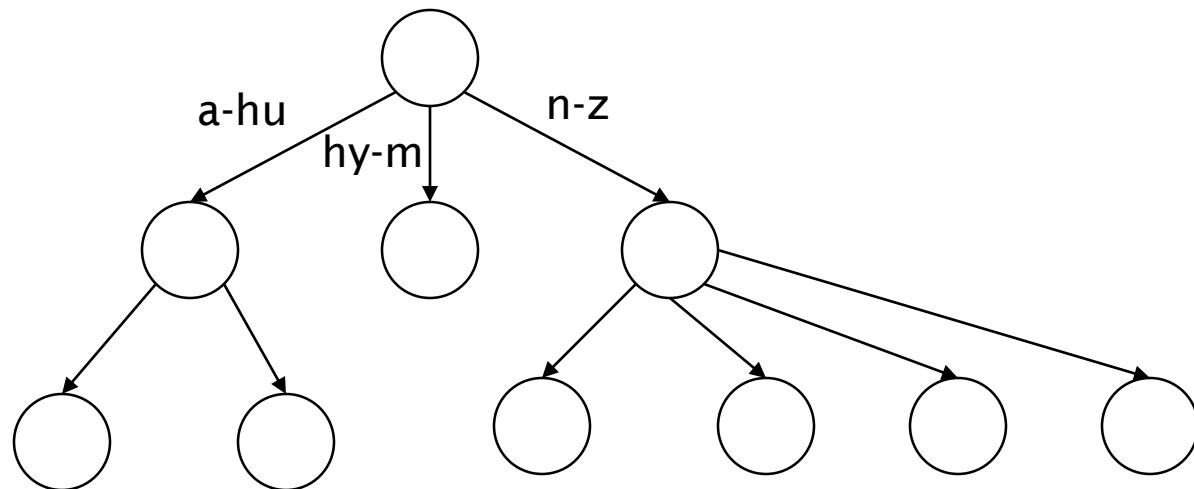
Δέντρα Αναζήτησης: Δυαδικό Δέντρο



Δέντρα Αναζήτησης: Δυαδικό Δέντρο

- $O(\log M)$, M : αριθμός των όρων (το μέγεθος του λεξικού)
 - προϋποθέτει ισοζύγιση

Δέντρα: Β-δέντρα



Ορισμός: Κάθε εσωτερικός κόμβος έχει έναν αριθμό από παιδιά στο διάστημα $[a, b]$ όπου a, b είναι κατάλληλοι φυσικοί αριθμοί, π.χ., [2, 4]

Δέντρα

- Το απλούστερο: δυαδικό δέντρο
- Το πιο συνηθισμένο: B-δέντρα
- Τα δέντρα απαιτούν ένα δεδομένο τρόπο διάταξης των χαρακτήρων (αλλά συνήθως υπάρχει ή μπορεί να οριστεί)

+:

- Λύνουν το πρόβλημα προθέματος (π.χ., όροι που αρχίζουν με *hyp*)
- Πλεονεκτούν όταν το λεξικό αποθηκεύεται στο δίσκο (τότε τα *a* και *b* καθορίζονται από το μέγεθος του block)

-:

- Πιο αργή: $O(\log M)$ [και αυτό απαιτεί (*ισοζυγισμένα (balanced)* δέντρα)
- Η επανα-ισοζύγιση (rebalancing) των δυαδικών δέντρων είναι ακριβή
 - Αλλά τα B-δέντρα καλύτερα

Ερωτήματα με *

Ερωτήματα με wild-card (*)

- (1) Δεν είμαστε σίγουροι για την ορθογραφία της λέξης (πχ Sydney? Sidney?)
- (2) Υπάρχουν πολλαπλές εκδοχές της ορθογραφίας της λέξης και θέλουμε να ανακτήσουμε τα έγγραφα που περιέχουν οποιαδήποτε από αυτές (πχ color, colour)
- (3) Δεν είμαστε σίγουροι αν έχει γίνει stemming
- (4) Ορθογραφία ξένης λέξης ($\Sigma^* \xi \pi^* \rho$)

Ερωτήματα με wild-card (*)

Trailing wild card query: το “*” εμφανίζεται μόνο μια φορά στο τέλος
(prefix query, πρόθημα)

- Π.χ., ***mon****: Βρες όλα τα έγγραφα που περιέχουν οποιαδήποτε λέξη αρχίζει με “*mon*”
 - Εύκολο όταν το λεξικό με δυαδικό δέντρο (ή Β-δέντρο):
 - ανάκτησε όλους τους όρους t στο διάστημα: $mon \leq t < mo\circ$
 - Για κάθε όρο, αναζήτησε το αντεστραμμένο ευρετήριο σε ποια έγγραφα εμφανίζεται

Ερωτήματα με wild-card (*)

Leading wild card queries: το “*” εμφανίζεται μόνο μια φορά στην αρχή (*postfix query, επίδημα*)

- **Π.χ., *mon:** Βρες όλα τα έγγραφα που περιέχουν οποιαδήποτε λέξη τελειώνει σε “mon”
- πιο δύσκολο
 - Διατήρησε ένα επιπρόσθετο B-tree για τους όρους ανάποδα (*backwards*), πχ ο όρος *demon* -> *nomed*
 - *Reverse B-tree*
 - Ανάκτησε όλους τους όρους t στο διάστημα: $nom \leq t < non$.

Ερωτήματα με wild-card (*)

Πως μπορούμε να απαντήσουμε ερωτήσεις με **ένα *** στη μέση της λέξης, π.χ., **pro*cent** ?

- Όροι με πρόθημα pro
- Όροι με επίθημα cent
- Διατρέχουμε τους όρους που ανήκουν στην **τομή** και απορρίπτουμε όσους ταιριάζουν και με το πρόθημα και με το επίθημα (αρκεί; ba*ba και όρος ba?)

Γενικά ερωτήματα με *

- * στη μέση του όρου
 - *co*tion*
- Αναζήτησε το *co** AND **tion* σε ένα B-δέντρο και ένα reverse B-δέντρο και υπολόγισε την τομή των συνόλων
 - Ακριβό!
- Δύο λύσεις – και οι δύο:
 - I. Έχουν ένα *ειδικό ευρετήριο*
 - II. Μετατρέπουν την αρχική ερώτησης q σε μια Boolean ερώτηση Q στο ειδικό ευρετήριο έτσι ώστε η απάντηση στο Q να είναι *υπερσύνολο* της απάντησης στο q
 - III. Στη συνέχεια ελέγχουν τις απαντήσεις

Γενικά ερωτήματα με *

Πρώτη εναλλακτική λύση:

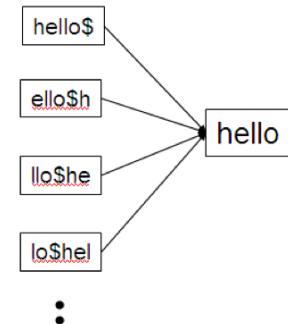
- Μετατροπή της ερώτησης με αντιμεταθέσεις (περιστροφές) ώστε το * να εμφανίζεται στο τέλος.
- Για κάθε όρο, αποθήκευση όλων των αντιμεταθέσεων του -> **Permuterm Index** (ευρετήριο αντιμετατεθειμένων όρων)
- Προθηματικό (prefix) ταίριασμα

Ευρετήριο αντιμετατεθειμένων όρων

Κατασκευάζουμε ένα (επιπρόσθετο) **ευρετήριο αντιμετατεθειμένων όρων (permuter index)** στο οποίο συνδέουμε όλες οι παραλλαγές που προκύπτουν από την **(δεξιόστροφη) περιστροφή (rotation)** με τον αρχικό όρο

Πχ. για τον όρο **hello** -> **hello\$**, εισάγουμε στο **λεξικό** τα:

- **hello\$, \$hello, o\$hell , lo\$hel , llo\$he, ello\$h**
- όπου **\$** ένα ειδικός χαρακτήρας που σηματοδοτεί το τέλος μιας λέξης
- Permuterm vocabulary



Περιστροφή (rotation) του όρου του ερωτήματος ώστε το * στο τέλος

Π.χ., Ερώτημα $he^*lo \rightarrow he^*lo\$ \rightarrow lo\he^*

Ψάχνουμε το $lo\$hel^*$ (ως prefix queries στο permuterm ευρετήριο – η δομή του το permuterm ευρετηρίου είναι κάποιο δέντρο αναζήτησης)

Ευρετήριο αντιμετατεθειμένων όρων

Παράδειγμα

Ευρετήριο αντιμετατεθειμένων όρων για **moron, man**

Εισάγουμε στο λεξικό όλες τις περιστροφές των όρων ώστε να δείχνουν στον αρχικό όρο
moron -> moron\$ -> στο λεξικό: **moron\$, \$moron, n\$moron, on\$mor, ron\$mo, oron\$man**

man -> man\$ -> στο λεξικό: **man\$, \$man, n\$ma, an\$man**

Ερώτημα m*n -> m*n\$ -> n\$m*

Ερώτημα: mo*n -> n\$mo*

Match?

Ερώτημα: m* -> \$m*

Match?

Ευρετήριο αντιμετατεθειμένων όρων

- **X*Y*Z** πως γίνεται match?
 - X*Y*Z\$ -> Z\$X*
 - Ψάξε Z\$X* και μετά έλεγξε κάθε υποψήφιο όρο για το Y
 - Πχ fi*mo*er -> ψάξε er\$fi*, έλεγξε αν και το (π.χ., fishmonger και fillbuster)
- Στην πραγματικότητα, permuted B-δέντρο για τους αντιμετατεθειμένους όρους
- *Πρόβλημα:* \approx δεκαπλασιάζει το μέγεθος του λεξικού

Εμπειρική παρατήρηση για τα Αγγλικά

Άσκηση

- Παράδειγμα permuted όροι για $baba$, ba και αποτέλεσμα των ba^*ba και ba^*

Ευρετήρια k -γραμμάτων (k -gram indexes)

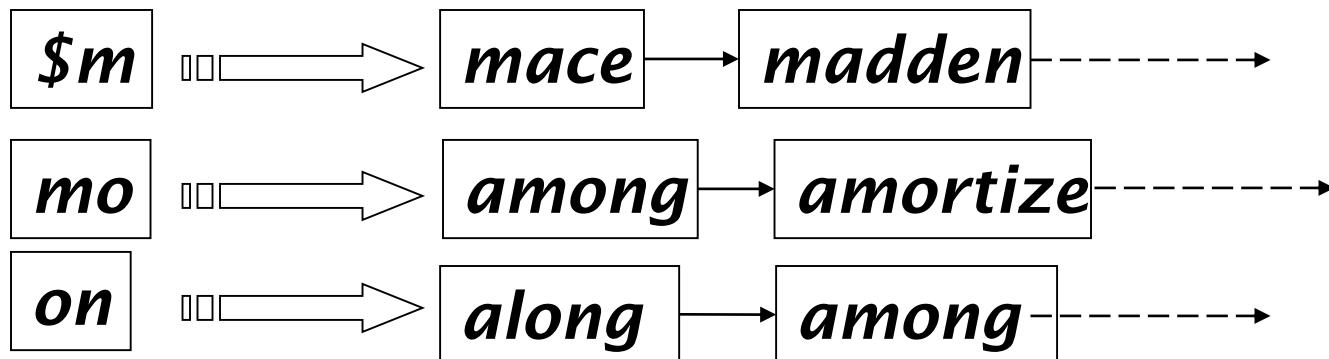
- k -gram: ακολουθία k χαρακτήρων
- Απαρίθμησε όλα τα k -γράμματα που εμφανίζονται σε κάθε όρο
 - π.χ., για το κείμενο “*April is the cruelest month*” έχουμε τα 2-γράμματα (bigrams)

```
$a,ap,pr,ri,il,I$, $i,is,s$, $t,th,he,e$, $c,cr,ru,  
ue,el,le,es,st,t$, $m,mo,on,nt,h$
```

- Όπου \$ ένα ειδικός χαρακτήρας που σηματοδοτεί το τέλος και την αρχή μιας λέξης
- Σε ένα k -gram ευρετήριο, το **λεξικό** περιέχει όλα τα k -grams που εμφανίζονται σε οποιονδήποτε όρο
- Διατήρησε ένα δεύτερο αντεστραμμένο ευρετήριο από τα k -γράμματα στους όρους του λεξικού που τα περιέχουν

Παράδειγμα ευρετηρίου k -γραμμάτων

- Το ευρετήριο k -γραμμάτων βρίσκει τους όρους βασισμένο σε μια ερώτηση που αποτελείται από k -γράμματα (εδώ $k=2$).



$k = 3$



Επεξεργασία ερωτημάτων

- Ερώτημα ***mon**** τώρα γίνεται
 - ***\$m AND mo AND on***
 - Βρίσκει τους όρους που ταιριάζουν μια AND εκδοχή του wildcard ερωτήματος.
- Απαιτείται βήμα μετά-φιλτραρίσματος (post-filter)
 - False positive, π.χ., moon
- Οι όροι που απομένουν αναζητούνται στο γνωστό αντεστραμμένο ευρετήριο όρων-εγγράφων

Άσκηση

- Γιατί οι λίστες καταχωρήσεων σε ένα ευρετήριο k-γραμμάτων είναι διατεταγμένες;

Επεξεργασία ερωτημάτων

- Ένα Boolean ερώτημα για κάθε όρο
- Μπορεί να οδηγήσουν σε ακριβή επεξεργασία ερωτημάτων
 - pyth* AND prog*
- Αν ενθαρρύνουμε την “τεμπελιά” οι άνθρωποι θα ανταποκριθούν!

Search

Type your search terms, use '*' if you need to.

E.g., Alex* will match Alexander.

- Ποιες μηχανές αναζήτησης επιτρέπουν τέτοια ερωτήματα; (*παλιότερα, altavista*)

Διόρθωση ορθογραφικών
λαθών

Διόρθωση ορθογραφικών λαθών

- Δύο βασικές χρήσεις
 - Διόρθωση των *εγγράφων* που ευρετηριοποιούνται
 - Διόρθωση των *ερωτημάτων* ώστε να ανακτηθούν «σωστές» απαντήσεις
- Δυο βασικές κατηγορίες:
 - *Μεμονωμένες λέξεις (isolated term)*
 - Εξέτασε κάθε λέξη μόνη της για λάθη
 - Δεν πιάνει τύπο που έχουν ως αποτέλεσμα σωστά γραμμένες λέξεις
 - π.χ., *from → form*
 - Βασισμένη σε *συμφραζόμενα* (context sensitive)
 - Κοιτά τις λέξεις γύρω,
 - π.χ., *I flew form Heathrow to Narita.*

Διόρθωση εγγράφων

- Χρήσιμη ιδιαιτερα για έγγραφα μετά από OCR
 - Αλγόριθμοι διόρθωσης ρυθμισμένοι για αυτό: την μοιάζει με την προσέταξη
 - Μπορεί να χρησιμοποιούν ειδική γνώση (domain-specific)
 - Π.χ., OCR μπερδεύει το Ο με το Ο πιο συχνά από το Ο και το Ι (που είναι γειτονικά στα QWERTY πληκτρολόγιο), οπότε πιο πιθανή η ανταλλαγή τους στην πληκτρολόγηση
- Άλλα συχνά: web σελίδες αλλά και τυπωμένο υλικό έχουν τύπος
- Στόχος: το λεξικό να περιέχει λιγότερα ορθογραφικά λάθη
 - Άλλα συχνά δεν αλλάζουμε τα έγγραφα αλλά επεκτείνουμε την απεικόνιση ερωτήματος – εγγράφου

Διόρθωση μεμονωμένης λέξης

- Θεμελιώδης υπόθεση – *υπάρχει ένα λεξικό που μας δίνει τη σωστή ορθογραφία*
- Δυο βασικές επιλογές για αυτό το λεξικό
 - Ένα *standard λεξικό* όπως
 - Webster's English Dictionary
 - Ένα "industry-specific" λεξικό – hand-maintained
 - Το *λεξικό της συλλογής* (corpus)
 - Π.χ., όλες οι λέξεις στο web
 - Όλα τα ονόματα, ακρώνυμα κλπ.
 - (συμπεριλαμβανομένων και των ορθογραφικών λαθών)

Γενικά θέματα

- (1) Στο ερώτημα carot πάντα επέστρεψε τα έγγραφα που περιέχουν το carot καθώς και τα έγγραφα με όλες τις διορθωμένες εκδοχές του όρου, πχ carrot and tarot.
- (2) Όπως στο (1), αλλά διορθώσεις μόνο αν το carot δεν είναι στο λεξικό
- (3) Όπως στο (1), αλλά μόνο αν η αρχική ερώτηση επιστρέφει λίγα (πχ λιγότερο από 5) έγγραφα.
- (4) Όταν η αρχική ερώτηση επιστρέφει λιγότερα από έναν προκαθορισμένο αριθμό από έγγραφα επιστρέφει «*spelling suggestions*» : “Did you mean carrot?” (και όχι επιπρόσθετα έγγραφα)

Γενικά θέματα

- (1) Επιστρέφουμε τη λέξη (λέξεις) που είναι πιο «κοντά»
- (2) Όταν ισοπαλία
 - (1) Την πιο συχνή (συχνές) στη συλλογή
 - (2) Την πιο συχνή στα ερωτήματα
 - Δείτε στο <http://www.netpaths.net/blog/britney-spears-spelling-variations/> (αρχικά εδώ <http://www.google.com/jobs/archive/britney.html>) στατιστικά για misspellings του Britney Spears
 - Ένας απλός spell corrector σε Python
<http://norvig.com/spell-correct.html>

Διόρθωση μεμονωμένης λέξης

Δοθέντων ενός λεξικού και μιας ακολουθίας χαρακτήρων Q , επέστρεψε τις λέξεις του λεξικού που είναι **πιο κοντά** στο Q

Τι σημαίνει “πιο κοντά”?

Θα εξετάσουμε δύο ορισμούς εγγύτητας (απόστασης):

- Την *απόσταση διόρθωσης* -- *edit distance* (Levenshtein distance) και την *σταθμισμένη* εκδοχή της -- weighted edit distance
- *Επικάλυψη (overlap) n-γραμμάτων*

Απόσταση διόρθωσης (Edit distance)

ΟΡΙΣΜΟΣ: Δοθέντων δυο αλφαριθμητικών (strings) S_1 and S_2 , ο ελάχιστος αριθμός πράξεων για τη μετατροπή του ενός στο άλλο

Συνήθως, οι πράξεις είναι σε επίπεδο χαρακτήρα

- **Levenshtein distance:** Πράξεις
 - (1) Insert – Εισαγωγή,
 - (2) Delete - Διαγραφή και
 - (3) Replace – Αντικατάσταση ενός χαρακτήρα (μερικές φορές: κόστος 2 ως delete-insert)
- **Damerau-Levenshtein distance:**
 - + Transposition - Αντιμετάθεση ενός χαρακτήρα

Απόσταση Διόρθωσης (Edit distance)

Παραδείγματα

Levenshtein distance: *dog-do*: 1, *dof-dog* *cat-cart*: 1, *cat-cut*: 1, *cat-act*: 2,
cat-dog: 3

Damerau-Levenshtein distance: *cat-act*: 1

- Γενικά υπολογίζεται με Δυναμικό Προγραμματισμό.
- Κοιτάξτε πχ το <http://www.let.rug.nl/kleiweg/lev/> για παραδείγματα.

Δυναμικός προγραμματισμός

- ✓ Εκφράζουμε το πρόβλημα ως συνδυασμό υπό-προβλημάτων – η βέλτιστη λύση βασίζεται στη βέλτιστη λύση του υπό-προβλήματος
 - ✓ Στην περίπτωση των αποστάσεων διόρθωσης – το υπό-πρόβλημα δυο προθημάτων:

Ο βέλτιστος τρόπος από μια λέξη σε μια άλλη, βασίζεται στο βέλτιστο τρόπο από κάποιο πρόθημα της πρώτης σε πρόθημα της δεύτερης
- ✓ Έναν πίνακα
 - ✓ Γραμμές: Γράμματα (προθήματα) της πρώτη λέξης
 - ✓ Στήλες: Γράμματα (προθήματα) της δεύτερης λέξης
 - ✓ Θέσεις του πίνακα: βέλτιστο κόστος (απόσταση)

Υπολογισμός απόστασης διόρθωσης

cats -> fast

String s_2

		f	a	s	t	
		0	1	2	3	4
String s_1	c	1	1	2	3	4
	a	2	2	1	2	3
	t	3	3	2	2	2
	s	4	4	3	2	3

- Κάθε στοιχείο $m[i, j]$ του πίνακα: το **βέλτιστο** κόστος (απόσταση) για να πάμε από το πρόθεμα μήκους i του s_1 στο πρόθεμα μήκους j του s_2

Πχ $m[3, 2]$ cat->fa
 $m[0, 3] \in (\text{κενό}) -> fas$

Δυναμικός προγραμματισμός

- ✓ Πως υπολογίζουμε τα στοιχεία του πίνακα;
- ✓ Επικαλυπτόμενες υπό-λύσεις:

- ✓ Βέλτιστο κόστος $m[i, j]$
 - Πχ $m[2, 3]$ ca -> fas

3 διαφορετικοί τρόποι

1. $m[i, j-1]$ από αριστερά (γραμμή)

$m[2, 2]$ ca -> fa (insert s)

2. $m[i-1, j]$ από πάνω (στήλη)

$m[1, 3]$ c->fas (delete a)

3. $m[i-1, j-1]$ (διαγώνια)

$m[1,2]$ c -> fa

i-1, j-1	i-1, j
i, j-1	i, j

Αλγόριθμος (από αριστερά)

LEVENShteINDISTANCE(s_1, s_2)

```

1  for  $i \leftarrow 0$  to  $|s_1|$ 
2  do  $m[i, 0] = i$ 
3  for  $j \leftarrow 0$  to  $|s_2|$ 
4  do  $m[0, j] = j$ 
5  for  $i \leftarrow 1$  to  $|s_1|$ 
6  do for  $j \leftarrow 1$  to  $|s_2|$ 
7    do if  $s_1[i] = s_2[j]$ 
8      then  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]\}$ 
9      else  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]+1\}$ 
10 return  $m[|s_1|, |s_2|]$ 

```

$i-1, j-1$	$i-1, j$
$i, j-1$	i, j

Operations: **insert (cost 1)**, delete (cost 1), replace (cost 1), copy (cost 0)

Αλγόριθμος (από πάνω)

LEVENSHTEINDISTANCE(s_1, s_2)

```

1  for  $i \leftarrow 0$  to  $|s_1|$ 
2  do  $m[i, 0] = i$ 
3  for  $j \leftarrow 0$  to  $|s_2|$ 
4  do  $m[0, j] = j$ 
5  for  $i \leftarrow 1$  to  $|s_1|$ 
6  do for  $j \leftarrow 1$  to  $|s_2|$ 
7    do if  $s_1[i] = s_2[j]$ 
8      then  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]\}$ 
9      else  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]+1\}$ 
10 return  $m[|s_1|, |s_2|]$ 
```

$i-1, j-1$	$i-1, j$
$i, j-1$	i, j



Operations: insert (cost 1), delete (cost 1), replace (cost 1), copy (cost 0)

Αλγόριθμος (διαγώνια)

LEVENSHTEINDISTANCE(s_1, s_2)

```

1  for  $i \leftarrow 0$  to  $|s_1|$ 
2  do  $m[i, 0] = i$ 
3  for  $j \leftarrow 0$  to  $|s_2|$ 
4  do  $m[0, j] = j$ 
5  for  $i \leftarrow 1$  to  $|s_1|$ 
6  do for  $j \leftarrow 1$  to  $|s_2|$ 
7    do if  $s_1[i] = s_2[j]$ 
8      then  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]\}$ 
9      else  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]+1\}$ 
10 return  $m[|s_1|, |s_2|]$ 

```

Αν το i -οστο στοιχείο του s_1 είναι διαφορετικό από το j -οστό στοιχείου του s_2

$i-1, j-1$	$i-1, j$
$i, j-1$	i, j

Operations: insert (cost 1), delete (cost 1), replace (cost 1), copy (cost 0)

Αλγόριθμος (διαγώνια)

LEVENSHTEIN DISTANCE(s_1, s_2)

```

1  for  $i \leftarrow 0$  to  $|s_1|$ 
2  do  $m[i, 0] = i$ 
3  for  $j \leftarrow 0$  to  $|s_2|$ 
4  do  $m[0, j] = j$ 
5  for  $i \leftarrow 1$  to  $|s_1|$ 
6  do for  $j \leftarrow 1$  to  $|s_2|$ 
7    do if  $s_1[i] = s_2[j]$ 
8      then  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]\}$ 
9      else  $m[i, j] = \min\{m[i-1, j]+1, m[i, j-1]+1, m[i-1, j-1]+1\}$ 
10 return  $m[|s_1|, |s_2|]$ 

```

Αν το i -οστο στοιχείο του s_1 είναι ίδιο με το j -οστό στοιχείου του s_2

$i-1, j-1$	$i-1, j$
$i, j-1$	i, j

Operations: insert (cost 1), delete (cost 1), replace (cost 1), **copy** (cost 0)

Υπολογισμός απόστασης Levenshtein

Για να υπολογίσουμε το $m[i, j]$

	$j - 1$	j
$i - 1$	Εξαρτάται από το επόμενο γράμμα	Κόστος από τον πάνω γείτονα (delete) $[i-1, j]$
i	κόστος από τον αριστερό γείτονα (insert) $[i, j-1]$	Το μικρότερο από τις 3 πιθανές για να φτάσουμε στο $[i, j]$

Υπολογισμός απόστασης διόρθωσης

LEVENSHTEIN DISTANCE(s_1, s_2)

```

1  for  $i \leftarrow 0$  to  $|s_1|$ 
2  do  $m[i, 0] = i$ 
3  for  $j \leftarrow 0$  to  $|s_2|$ 
4  do  $m[0, j] = j$ 
5  for  $i \leftarrow 1$  to  $|s_1|$ 
6  do for  $j \leftarrow 1$  to  $|s_2|$ 
7    do if  $s_1[i] = s_2[j]$ 
8      then  $m[i, j] = \min$ 
9      else  $m[i, j] = \min$ 
10 return  $m[|s_1|, |s_2|]$ 
```

Operations: insert (cost 1), delete (cost 0)

Αρχικοποίηση

String s_2

		f	a	s	t
	0	1	2	3	4
c	1	1	2	3	4
a	2	2	1	2	3
t	3	3	2	2	2
s	4	4	3	2	3

String s_1

Κόστος διόρθωσης για τα προθέματα

Υπολογισμός απόστασης Levenshtein

Κόστος από τον πάνω αριστερό γείτονα Copy ή Replace	Κόστος από τον πάνω γείτονα Delete
Κόστος από τον αριστερό γείτονα Insert	Το μικρότερο από τα 3 κόστη

Υπολογισμός απόστασης Levenshtein: παράδειγμα

		f	a	s	t
	0	1 1	2 2	3 3	4 4
c	1	1 2	2 3	3 4	4 5
	1	2 1	2 2	3 3	4 4
a	2	2 2	1 3	3 4	4 5
	2	3 2	3 1	2 2	3 3
t	3	3 3	3 2	2 3	2 4
	3	4 3	4 2	3 2	3 2
s	4	4 4	4 3	2 3	3 3
	4	5 4	5 3	4 2	3 3

Δυναμικός προγραμματισμός

1. Βέλτιστη υπό-δομή (Optimal substructure): Η βέλτιστη λύση σε ένα πρόβλημα περιέχει τις υπό-λύσεις, δηλαδή τις βέλτιστες λύσεις σε υπό-προβλήματα
2. Επικαλυπτόμενες υπό-λύσεις (Overlapping subsolutions): Οι υπο-λύσεις υπολογίζονται ξανά και ξανά όταν υπολογίζονται οι ολικές βέλτιστες λύσεις στον brute-force αλγόριθμο.

Δυναμικός προγραμματισμός

- ✓ Στην περίπτωση των αποστάσεων διόρθωσης – το υπό-πρόβλημα δυο προθημάτων
- ✓ Οι επικαλυπτόμενες υπό-λύσεις: χρειαζόμαστε τις περισσότερες αποστάσεις 3 φορές: κίνηση δεξιά, στη διαγώνιο, κάτω

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o	1	1	2							
	1		2	?						
s	2									
l	3									
	3									
o	4									
	4									

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1			
s	2 2				
l	3 3				
o	4 4				

replace o with s

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o		1	1	2	2	3	3		4	4
s		2								
l		3								
o		4								

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o		1	1	2	2	3	3			
o		1	2	1	2	2				
s		2								
		2								
l		3								
		3								
o		4								
		4								

(διαγώνιο) replace o with n, insert s

(αριστερά-γραμμή) insert n, replace o with s

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 ?	
s	2 2				
l	3 3				
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

			s	n	o	w	
			0	1 1	2 2	3 3	4 4
o		1	1 2	2 3	2 4		
s		2					
		2					
l		3					
		3					
o		4					
		4					

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 ?
s	2				
l	3				
l	3				
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2				
l	3 3				
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
		0	1 1	2 2	3 3
o		1 1	1 2 2 1	2 3 2 2	2 4 3 2
s		2 2	1 2 3 ?		
l		3 3			
o		4 4			

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2			
s	2	3 1			
l	3				
l	3				
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3		
s	2	3 1	2 ?		
l	3				
l	3				
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o	1	1	2	2	3	2	4	4	5	
	1	2	1	2	2	2	3	2	3	
s	2	1	2	2	3					
l	3									
	3									
o	4									
	4									

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 ?	
l	3 3				
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	
l	3 3				
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 ?
l	3 3				
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3				
l	3				
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w	
	0	1	1	2	2	3	3	4	4
o	1	1	2	3	2	4	4	5	
o	1	2	1	2	2	3	2	3	3
s	2	1	2	3	2	3	3	3	4
l	3	3	2						
l	3	4	?						
o	4								
o	4								

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2			
l	3	4 2			
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3		
l	3	4 2	3 ?		
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2		
o	4 4				

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	
l	3	4 2	3 2	3 ?	
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o		1	1	2	2	3	2	4	4	5
		1	2	1	2	2	3	2	3	3
s		2	1	2	2	3	3	3	3	4
		2	3	1	2	2	3	3	4	3
l		3	3	2	2	3	3	4		
		3	4	2	3	2	3	3		
o		4								
		4								

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 ?
o	4				
o	4				

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w	
		0	1	1	2	2	3	3	4
	o	1	1	2	2	3	4	5	
		1	2	1	2	2	3	2	3
	s	2	1	2	2	3	3	3	4
		2	3	1	2	2	3	3	4
	l	3	3	2	2	3	4	4	4
		3	4	2	3	2	3	3	4
	o	4							
		4							

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2	3 4 3 3	4 4 4 4
o	4 4	4 3 5 ?			

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o	1	1	2		2	3	2	4	4	5
	1	2	1		2	2	3	2	3	3
s	2	1	2		2	3	3	3	3	4
	2	3	1		2	2	3	3	4	3
l	3	3	2		2	3	3	4	4	4
	3	4	2		3	2	3	3	4	4
o	4	4	3							
	4	5	3							

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3		
o	4	5 3	4 ?		

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3		
o	4	5 3	4 3		

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o	0	1	1	2	2	3	3	4	4	5
	1	2	1	2	2	2	3	2	3	3
s	2	1	2	2	3	3	3	3	3	4
	2	3	1	2	2	3	3	3	4	3
l	3	3	2	2	3	3	4	4	4	4
	3	4	2	3	2	3	3	3	4	4
o	4	4	3	3	3	3	2	4		
	4	5	3	4	3	4	4	?		

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2	3 4 3 3	4 4 4 4
o	4 4	4 3 5 3	3 3 4 3	2 4 4 2	

Υπολογισμός απόστασης: παράδειγμα

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o	1	1	2	2	3	2	4	4	5	
	1	2	1	2	2	2	3	2	3	3
s	2	1	2	2	3	3	3	3	3	4
	2	3	1	2	2	2	3	3	4	3
l	3	3	2	2	3	3	3	4	4	4
	3	4	2	3	2	3	3	3	4	4
o	4	4	3	3	3	3	2	4	4	5
	4	5	3	4	3	4	4	2	3	?

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2	3 4 3 3	4 4 4 4
o	4 4	4 3 5 3	3 3 4 3	2 4 4 2	4 5 3 3

Υπολογισμός απόστασης: παράδειγμα

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2	3 4 3 3	4 4 4 4
o	4 4	4 3 5 3	3 3 4 3	2 4 4 2	4 5 3 3

Πως μπορώ να δω τις πράξεις που οδήγησαν από OSLO σε SNOW?

		s		n		o		w		
		0	1	1	2	2	3	3	4	4
o		1	1	2	3	2	4	4	5	
		1	2	1	2	2	3	2	3	3
s		2	1	2	3	2	3	3	4	
		2	3	1	2	2	3	3	4	3
l		3	3	2	2	3	3	4	4	4
		3	4	2	3	2	3	3	4	4
o		4	4	3	3	3	3	2	4	5
		4	5	3	4	3	4	2	3	3

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3	2 4	4 5
o	4	5 3	4 3	4 2	3 3

cost	operation	input	output
1	insert	*	w

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3	2 4	4 5
o	4	5 3	4 3	4 2	3 3

cost	operation	input	output
0	(copy)	o	o
1	insert	*	w

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3	2 4	4 5
o	4	5 3	4 3	4 2	3 3

cost	operation	input	output
1	replace		n
0	(copy)	o	o
1	insert	*	w

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1	1 2	2 3	2 4	4 5
o	1	2 1	2 2	3 2	3 3
s	2	1 2	2 3	3 3	3 4
s	2	3 1	2 2	3 3	4 3
l	3	3 2	2 3	3 4	4 4
l	3	4 2	3 2	3 3	4 4
o	4	4 3	3 3	2 4	4 5
o	4	5 3	4 3	4 2	3 3

cost	operation	input	output
0	(copy)	s	s
1	replace	l	n
0	(copy)	o	o
1	insert	*	w

		s	n	o	w
	0	1 1	2 2	3 3	4 4
o	1 1	1 2 2 1	2 3 2 2	2 4 3 2	4 5 3 3
s	2 2	1 2 3 1	2 3 2 2	3 3 3 3	3 4 4 3
l	3 3	3 2 4 2	2 3 3 2	3 4 3 3	4 4 4 4
o	4 4	4 3 5 3	3 3 4 3	2 4 4 2	4 5 3 3

cost	operation	input	output
1	delete	o	*
0	(copy)	s	s
1	replace	l	n
0	(copy)	o	o
1	insert	*	w

Πως μπορώ να δω τις πράξεις που οδήγησαν από CAT σε CATCAT?

		c	a	t	c	a	t
	0	1 1	2 2	3 3	4 4	5 5	6 6
c	1	0 2	2 3	3 4	3 5	5 6	6 7
	1	2 0	1 1	2 2	3 3	4 4	5 5
a	2	2 1	0 2	2 3	3 4	3 5	5 6
	2	3 1	2 0	1 1	2 2	3 3	4 4
t	3	3 2	2 1	0 2	2 3	3 4	3 5
	3	4 2	3 1	2 0	1 1	2 2	3 3

		c	a	t	c	a	t
	0	1 1	2 2	3 3	4 4	5 5	6 6
c	1	0 2	2 3	3 4	3 5	5 6	6 7
c	1	2 0	1 1	2 2	3 3	4 4	5 5
a	2	2 1	0 2	2 3	3 4	3 5	5 6
a	2	3 1	2 0	1 1	2 2	3 3	4 4
t	3	3 2	2 1	0 2	2 3	3 4	3 5
t	3	4 2	3 1	2 0	1 1	2 2	3 3

cost	operation	input	output
1	insert	*	c
1	insert	*	a
1	insert	*	t
0	(copy)	c	c
0	(copy)	a	a
0	(copy)	t	t

		c	a	t	c	a	t
	0	1 1	2 2	3 3	4 4	5 5	6 6
c	1	0 2	2 3	3 4	3 5	5 6	6 7
	1	2 0	1 1	2 2	3 3	4 4	5 5
a	2	2 1	0 2	2 3	3 4	3 5	5 6
	2	3 1	2 0	1 1	2 2	3 3	4 4
t	3	3 2	2 1	0 2	2 3	3 4	3 5
	3	4 2	3 1	2 0	1 1	2 2	3 3

cost	operation	input	output
0	(copy)	c	c
1	insert	*	a
1	insert	*	t
1	insert	*	c
0	(copy)	a	a
0	(copy)	t	t

		c	a	t	c	a	t	
		0	1 1	2 2	3 3	4 4	5 5	6 6
c	1	0 2	2 3	3 4	3 5	5 6	6 7	
c	1	2 0	1 1	2 2	3 3	4 4	5 5	
a	2	2 1	0 2	2 3	3 4	3 5	5 6	
a	2	3 1	2 0	1 1	2 2	3 3	4 4	
t	3	3 2	2 1	0 2	2 3	3 4	3 5	
t	3	4 2	3 1	2 0	1 1	2 2	3 3	

cost	operation	input	output
0	(copy)	c	c
0	(copy)	a	a
1	insert	*	t
1	insert	*	c
1	insert	*	a
0	(copy)	t	t

		c	a	t	c	a	t
	0	1 1	2 2	3 3	4 4	5 5	6 6
c	1	0 2	2 3	3 4	3 5	5 6	6 7
c	1	2 0	1 1	2 2	3 3	4 4	5 5
a	2	2 1	0 2	2 3	3 4	3 5	5 6
a	2	3 1	2 0	1 1	2 2	3 3	4 4
t	3	3 2	2 1	0 2	2 3	3 4	3 5
t	3	4 2	3 1	2 0	1 1	2 2	3 3

cost	operation	input	output
0	(copy)	c	c
0	(copy)	a	a
0	(copy)	t	t
1	insert	*	c
1	insert	*	a
1	insert	*	t

Σταθμισμένη απόσταση διόρθωσης

- Το βάρος μιας πράξης εξαρτάται από τον ποιο χαρακτήρα (χαρακτήρες) αφορά
 - Στόχος να λάβει υπόψη λάθη OCR ή πληκτρολόγησης
Παράδειγμα: **m** πιο πιθανό να πληκτρολογηθεί ως **n** παρά ως **q**
 - Οπότε η αντικατάσταση του **m** από **n** έχει μικρότερη απόσταση διόρθωσης από την απόσταση του από το **q**
 - Διατύπωση ως πιθανοτικό μοντέλο
- Προϋποθέτει ως είσοδο έναν **πίνακα βαρών**
- *Πως θα μετατρέψουμε το δυναμικό προγραμματισμό για να χειριστούμε τα βάρη;*

Επικάλυψη k -γραμμάτων

Εναλλακτικός ορισμός απόστασης με βάση τα κοινά k -γράμματα

- Η ομοιότητα δυο όρων είναι ίση με τον αριθμό των κοινών k -γραμμάτων τους

Παράδειγμα

3-γράμματα

november

- Τα τριγράμματα είναι *nov*, *ove*, *vem*, *emb*, *mbe*, *ber*.

december

- Τα τριγράμματα είναι *dec*, *ece*, *cem*, *emb*, *mbe*, *ber*.

Άρα 3 τριγράμματα επικαλύπτονται (από τα 6 κάθε όρου) – ομοιότητα 3

Μια δυνατότητα – συντελεστής Jaccard

- Συνήθης μέτρηση της επικάλυψης

Έστω X και Y δύο σύνολα, ο συντελεστής Jaccard (Jaccard coefficient) ορίζεται ως:

$$|X \cap Y| / |X \cup Y|$$

- Ίσος με 1 όταν τα X και Y έχουν τα ίδια στοιχεία και 0 όταν είναι ξένα
- Τα X and Y δε χρειάζεται να έχουν το ίδιο μέγεθος
- Πάντα μεταξύ του 0 και του 1
 - Το κατώφλι καθορίζει αν υπάρχει ταίριασμα, πχ., αν $J.C. > 0.8$, τότε ταίριασμα

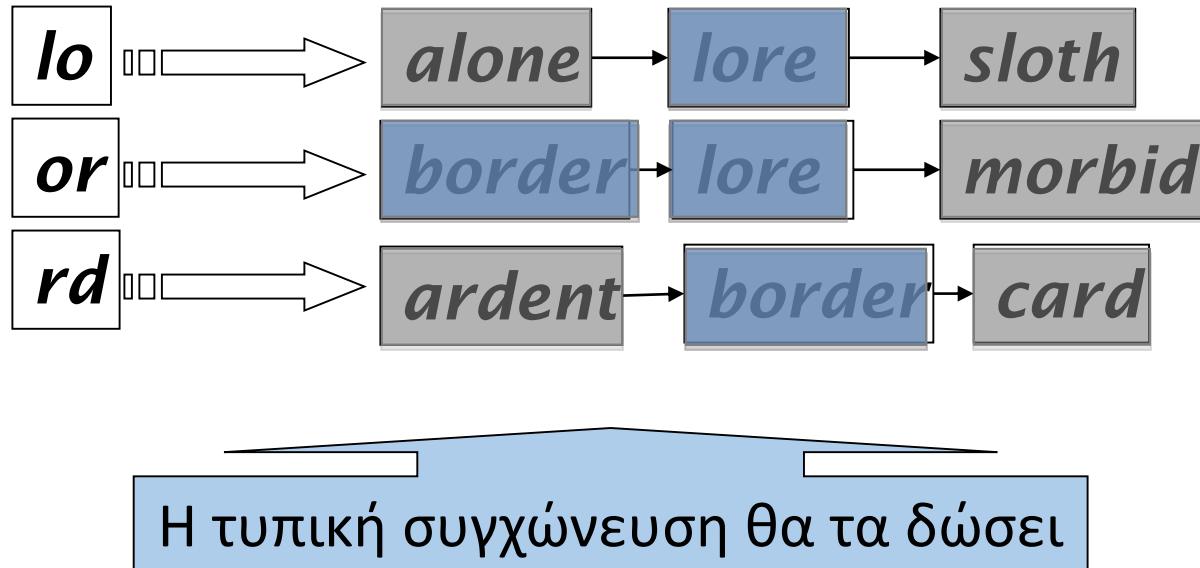
Πως το υπολογίζουμε αποδοτικά στην περίπτωση των k -γραμμάτων;

Επικάλυψη k -γραμμάτων

- Απαρίθμησε όλα το k -γράμματα στον όρο της ερώτησης
- Χρησιμοποίησε το ευρετήριο k -γραμμάτων για να ανακτήσεις όλους τους όρους του λεξικού που ταιριάζουν κάποιο από τα k -γράμματα του ερωτήματος
- Ανέκτησε όλους τους όρους του λεξικού που ταιριάζουν κάποιο ($>=$ **κατώφλι**) αριθμό από τα k -γράμματα του ερωτήματος

Παράδειγμα: Ταίριασμα 2-γραμμάτων

- Έστω το ερώτημα **lord** – θέλουμε να βρούμε τις λέξεις που ταιριάζουν του λάχιστον 2 από τα 3 διγράμματα (**lo**, **or**, **rd**)



Για το JC χρειαζόμαστε και τον αριθμό των 2-γραμμάτων (το μήκος της λέξης)

Απόσταση διόρθωσης από όλους τους όρους του λεξικού;

- Διοθέντος ενός (ανορθόγραφου) ερωτήματος, υπολογίζουμε την απόσταση διόρθωσης από όλους τους όρους του λεξικού
 - Ακριβό και αργό
- Μπορούμε να μειώσουμε τον αριθμό των υποψήφιων όρων του ευρετηρίου;
 - Μόνο λέξεις που αρχίζουν από το ίδιο γράμμα
 - Να θεωρήσουμε ότι υπάρχει * και ένα permuted (με κάποιες τροποποιήσεις)
 - Να βρούμε λέξεις με αρκετά κοινά k -γράμματα και να περιορίσουμε τον υπολογισμό απόστασης με αυτές

Χρήση των αποστάσεων διόρθωσης

1. Ή, διθείσας μιας ερώτησης, πρώτα απαρίθμησε όλες τις ακολουθίες χαρακτήρων μέσα σε μια προκαθορισμένη (σταθμισμένη) απόσταση διόρθωσης (π.χ., 2)
2. Βρες την τομή αυτού του συνόλου με τις «σωστές» λέξεις
3. *Πρότεινε τους όρους* που βρήκες στο χρήστη
 - Ψάξε όλες τις πιθανές διορθώσεις στο αντεστραμμένο ευρετήριο και επέστρεψε όλα τα έγγραφα ... αργό
 - Μπορούμε να *επιστρέψουμε τα έγγραφα* μόνο για την πιο πιθανή διόρθωση (πχ τη πιο συνηθισμένη λέξη) ή τη διόρθωση που επιλέγουν οι χρήστες πιο συχνά (*hit-based correction*)
 - Η εναλλακτική λύση παίρνει τον έλεγχο από το χρήστη αλλά κερδίζουμε ένα γύρο διάδρασης

Διόρθωση εξαρτώμενη από το περιβάλλον

Κείμενο: *I flew from Heathrow to Narita.*

- Θεωρείστε το ερώτημα-φράση “**flew from Heathrow**”
- Θα θέλαμε να απαντήσουμε

Did you mean “**flew from Heathrow**”?

Γιατί δεν υπάρχουν (αρκετά) έγγραφα που να ταιριάζουν στο αρχικό ερώτημα φράση

Διόρθωση βασισμένη στα συμφραζόμενα

Χρειάζεται συμφραζόμενο περιβάλλον για να το πιάσει αυτό.

Πρώτη ιδέα:

1. Ανέκτησε τους όρους του λεξικού που είναι κοντά (σε σταθμισμένη απόσταση διόρθωσης) από κάθε όρο του ερωτήματος (ακόμα και για αυτές χωρίς λάθος)
2. Δοκίμασε όλες τις πιθανές φράσεις που προκύπτουν κρατώντας κάθε φορά μια λέξη σταθερή
 - *flew from heathrow*
 - *fled form heathrow*
 - *flea form heathrow*
3. *Hit-based spelling correction*: Πρότεινε την εναλλακτική με τα περισσότερα hits

Διόρθωση βασισμένη στα συμφραζόμενα

Εναλλακτική Προσέγγιση με χρήση biwords

1. Σπάσε της φράση σε σύζευξη biwords.
2. Ψάξε τα biwords που χρειάζονται διόρθωση μόνο ενός όρου.
3. Απαρίθμησε μόνο τις φράσεις που περιέχουν «κοινά» biwords.

ΦΩΝΗΤΙΚΗ ΔΙΟΡΘΩΣΗ (Soundex)

Soundex

Φωνητική διόρθωση: ερώτημα που «ακούγεται»
όπως ο σωστός όρος

- Κλάση ευριστικών για την επέκταση ενός ερωτήματος σε φωνητικά (*phonetic*) ισοδύναμα
 - Εξαρτώνται από τη γλώσσα – κυρίως για ονόματα
 - Π.χ., *chebyshev* → *tchebycheff*
 - Προτάθηκε από το U.S. census ... το 1918 (για ονόματα από εγκληματίες!)

Βασική ιδέα: “*phonetic hash*”: όροι που «ακούγονται» ίδιοι κατακερματίζονται στην ίδια θέση

Soundex – τυπικός αλγόριθμος

- Μετέτρεψε κάθε token προς δεικτοδότηση σε μια μορφή 4-χαρακτήρων
- Το ίδιο και για τους όρους του ερωτήματος
- Κατασκεύασε ένα ανεστραμμένο ευρετήριο από αυτούς τους 4-χαρακτήρες στον αρχικό όρο και ψάξε στο ευρετήριο τις μειωμένες μορφές
 - (όταν το ερώτημα χρειάζεται φωνητικό ταίριασμα)

<http://www.creativyst.com/Doc/Articles/SoundEx1/SoundEx1.htm#Top>

Soundex – τυπικός αλγόριθμος

1. Κράτησε τον πρώτο χαρακτήρα της λέξης
2. Μετάτρεψε όλες τις εμφανίσεις των παρακάτω όρων σε '0' (zero):
'Α', 'Ε', 'Ι', 'Ο', 'Υ', 'Η', 'Ω', 'Υ'.
3. Άλλαξε τα γράμματα σε αριθμούς ως ακολούθως:
 - Β, Φ, Ρ, Β → 1
 - Σ, Γ, Ι, Κ, Ζ, Σ, Χ, Ζ → 2
 - Δ, Τ → 3
 - Λ → 4
 - Μ, Ν → 5
 - Ρ → 6

Σημασία το πρώτο γράμμα, όλα τα φωνήεντα το ίδιο, σύμφωνα που ακούγονται το ίδιο

Soundex συνέχεια

4. Σβήσε όλα τα ζεύγη συνεχόμενων ίδιων αριθμών
5. Σβήσε όλα τα απομένοντα 0
6. Πρόσθεσε 0 στο τέλος και επέστρεψε τις τέσσερις πρώτες θέσεις που θα είναι της μορφής <uppercase letter> <digit> <digit> <digit>.

Π.χ., *Herman* γίνεται H655.

To *hermann* δίνει τον ίδιο κωδικό;

ΤΕΛΟΣ 3^{ου} Κεφαλαίου

Ερωτήσεις?

Χρησιμοποιήθηκε κάποιο υλικό των:

- ✓ Pandu Nayak and Prabhakar Raghavan, *CS276:Information Retrieval and Web Search (Stanford)*
- ✓ Hinrich Schütze and Christina Lioma, *Stuttgart IIR class*