



Εισαγωγή στη Βιοπληροφορική

Ενότητα 7: Αλγόριθμοι εναλλακτικών προσεγγιστικών ταιριασμάτων βιολογικών δεδομένων

Μακρής Χρήστος, Τσακαλίδης Αθανάσιος,
Περδικούρη Αικατερίνη
Πολυτεχνική Σχολή
Τμήμα Μηχανικών Η/Υ και Πληροφορικής

Σκοποί ενότητας

- Σκοπός της ενότητας είναι η παρουσίαση εναλλακτικοί αλγόριθμοι προσεγγιστικού ταιριάσματος βιολογικών δεδομένων



Βασικές Βιβλιογραφικές Πηγές στις οποίες βασίζονται οι διαφάνειες

- Costas S. I Costas S. Iliopoulos, Christos Makris, Yannis Panagis, Katerina Perdikuri, Evangelos Theodoridis, Athanasios K. Tsakalidis: The Weighted Suffix Tree: An Efficient Data Structure for Handling Molecular Weighted Sequences and its Applications. Fundam. Informaticae 71(2-3): 259-277 (2006)
- Maxime Crochemore, Costas S. Iliopoulos, Christos Makris, Wojciech Rytter, Athanasios K. Tsakalidis, T. Tsichlas: Approximate String Matching with Gaps. Nord. J. Comput. 9(1): 54-65 (2002)

Motivation

- DNA sequencing processes large chains into subsequences of ~500 characters long
- Assembling all pieces, produces a single sequence but...
 - At some positions we have uncertainty
 - Uncertainty: NOT '*' each character appears with some probability



Weighted Sequence

	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}	S_{11}
A	1	0	0	0	0.5	0	0	0.5	0	0	0
C	0	1	0	0	0.5	0	1	0.3	0	0	0
G	0	0	0	0	0	0	0	0	0	0	0
T	0	0	1	1	0	1	0	0.2	1	1	1



Definitions

- ✓ Word w : a sequence of zero or more characters from an alphabet Σ .
- ✓ $w = w[1]w[2]\dots w[n]$ or $w[1..n]$
- ✓ Subword $u = w[i..i+p-1]$. If $i=1$, u is a prefix. If $i+p-1 = n$, u is a suffix.
- ✓ Repeat: At least two equal subwords u



Definitions (cont'd)

Repetition: *At least two consecutive equal subwords*

$$u_1 = w[i..i+p-1] = u_2 = w[i+p..i+2*p-1] = \dots$$

Example: $w = abaabab$

abaaba
aa
abab

Cover u : A repeated subword that covers the entire sequence (allowing catenations and overlaps)



Weighted words

Weighted word $w = w_1 w_2 \dots w_n$.

- $w_i = \{(\sigma_1, p_i(\sigma_1)), (\sigma_2, p_i(\sigma_2)), \dots\}$
- $\sigma \in \Sigma$ and

Example: $\sum_{\forall \sigma} p_i = 1$

$$\Sigma = \{A, C, G, T\}$$

1	2	3	4	5	6	7	8	9	10	11
A	C	T	T	(A, 0.5)	T	C	(A, 0.5)	T	T	T
				(C, 0.5)			(C, 0.3)			
				(G, 0)			(G, 0)			


Q: Which subwords occur with probability $\geq 1/4$?

A: ACTTATCATT (0.25), ACTTCTCATT (0.25) ATTT (0.5), CTTT(0.3) **and all their subwords** (but not ACTTATCCTTT)



Suffix trees

- ✓ Suffix tree $T(S)$ of a sequence S , $|S| = n$ is the *compact trie* of all the suffixes of $S\$$, $\$ \notin \Sigma$.
 - Leaf v is labeled with integer i if stores $S[i..n]$
 - At internal node v
 - $LL(v)$ = list of suffixes at its descendants (*leaf-list*)
 - $L(v)$ = the string spelled from root to v (*path label*)
 - Can be built in $O(n)$ time and space




Suffix tree for
bcabc\$



Suffix trees (cont'd)

✓ Generalised Suffix Tree (GST)

- Multistring Suffix Tree for S_1, S_2, \dots, S_m
- Leaves can store labels for several strings
- Can be built in $O(|S_1| + |S_2| + \dots + |S_m|)$ time and space



Weighted Suffix Tree


- ✓ The generalised suffix tree for all the subwords of a weighted sequence S , $|S| = n$, where $\Pr(S) \geq 1/k$, k a fixed parametre.
 - Leaf v labeled with a pair (i, j) , for the subword $S_{i,j}$ (the j -th subword starting at position i)

1	2	3	4	5	6	7	8	9	10	11
A	C	T	T	(A, 0.5)	T	C	(A, 0.5)	T	T	T
				(C, 0.5)			(C, 0.3)			
				(G, 0)			(G, 0)			
				(T, 0)			(T, 0.2)			

$S_{1,1} = \text{ACTTATCA}\textcolor{blue}{T}\text{TTT\$}$, $S_{1,2} = \text{ACTTCTCA}\textcolor{blue}{T}\text{TTT\$}$, ... $S_{8,1} = \textcolor{blue}{A}\text{TTT\$}$



An example



Applications (1/4)

- ✓ Pattern Matching in weighted sequences, with $\Pr > 1/k$
- ✓ Build tree for S . Then as in ordinary suffix tree:
- ✓ Solid pattern P , P is spelled from the root of the tree. Stops at internal node. Report all leaves if necessary.
- ✓ Weighted pattern P , Break P into solid subwords and proceed as with solid patterns.

- ✓ Time: $O(m)$, $O(n)$ preprocessing $|S| = n$, $|P| = m$



Applications (2/4)

- ✓ Repeats in weighted sequences with $\Pr > 1/k$ for each.
 - Build WST for S with parameter $1/k$.
 - Traverse the WST, in DFS. At the return step to an internal node v , build leaf-lists $\text{LL}(v)$ from descendants.
 - $\text{LL}(v)$'s contents are positions where string $\text{Path-label}(v)$ is repeated.
- ✓ Time: $O(n+a)$ $|S| = n$, a = answer size



Applications (3/4)

- ✓ Longest Common Substring in weighted sequences with $\Pr > 1/k$
 - Build *Generalised Weighted Suffix Tree* for S_1, S_2 .
 - Each internal node = a common substring
 - Find longest path label
- ✓ Time: $O(|S_1| + |S_2|)$.



Applications (4/4)

- ✓ Haplotype inference
- ✓ Indeterminate strings
- ✓ Degenerate strings



Computational Molecular Biology Goals

- Finding regularities in nucleic or protein sequences
- Finding features that are common to such sequences




Gene Expression and Regulation

- Match “structured patterns”
- Infer “structured patterns”



Approximate Matching

String Matching with Gaps: The occurrences of the symbols of pattern p do not appear successively but have gaps.



Definitions

- ✓ Σ : Alphabet Σ^* : set of all strings over Σ
- ✓ Assume $a, b \in \Sigma$ and p (pattern), t (text) are strings over Σ .
- ✓ Assume that $g_i = j_{i+1} - j_i - 1$ is the gap between the occurrences of symbols p_{i+1} and p_i that occur at positions j_{i+1} and j_i in text t .

1. $p = p_1, p_2, \dots, p_m$, ($|p| = m$)
2. $a =_\delta b$ iff $|a - b| \leq \delta$
3. $p =_\delta t$ iff $p_i =_\delta t_i$ $1 \leq i \leq n$ (*δ -approximate*)
4. $p =_\gamma t$ iff $|p| = |t|$ and $\sum_{1 \leq i \leq |p|} |p_i - t_i| < \gamma$ (*γ -approximate*)



δ -approximate string matching with α -bounded gaps

- ✓ *Problem:* We want to bound the gap between the δ -occurrences of p_i and p_{i+1} in text t by α .
- ✓ *Basic Idea:* Compute the δ -occurrences of continuously increasing prefixes of p in t .



δ -approximate string matching with α -bounded gaps (the algorithm)

The basic structure is the $(m+1) \times (n+1)$ matrix D ($m=|p|$ & $n=|t|$):

$$D_{i,j} = \begin{cases} j, & \text{if } (t_j =_{\delta} p_i) \text{ and } (j - D_{i-1,j-1} \leq \alpha + 1) \text{ and } (D_{i-1,j-1} > 0) \\ D_{i,j-1}, & \text{if } (t_j \neq_{\delta} p_i) \text{ and } (j - D_{i,j-1} < \alpha + 1) \\ 0, & \text{otherwise} \end{cases}$$

$$D_{0,0}=1, D_{i,0}=0, D_{0,j}=j$$



Example: $t=\text{aca}\textcolor{red}{e}\text{cace}\textcolor{blue}{a}\text{eeac}\textcolor{blue}{b}\textcolor{blue}{e}$ ($n=15$) $p=\text{ace}$ ($m=3$) ($\alpha=1$, $\delta=1$)


1	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	1	3	3	0	6	6	0	9	9	0	12	12	0	0
0	0	2	2	0	5	5	7	7	0	0	0	0	13	14	14
0	0	0	0	4	0	0	0	8	0	0	0	0	0	0	15



(δ, γ) -approximate string matching with α -bounded gaps

Use matrix D combined with *min-FIFO queue* to keep track of the occurrences of the pattern symbols.

For each p_i , we maintain a list (as we construct the matrix D column by column) that keeps all the occurrences of p_{i-1} for which the invariant of the bounded gap is not violated. We also need a matrix C with the costs of the occurrences.



Complexities

- ✓ For δ -approximate α -bounded gaps $O(mn)$ time complexity and $O(mn)$ space ($O(m)$) if we notice that for the computation of column i we only need column $i-1$).
- ✓ For (δ, γ) -approximate α -bounded gaps $O(mn)$ time complexity and $O(mn + m\alpha)$ space.



α -strict bounded gaps and unbounded gaps

- ✓ α -strict bounded gaps: The gaps in this version are strictly of length α .
 - ✓ Solution: Rearrange text t so that symbols α far away become adjacent. Then use a standard algorithm for δ -approximate matching (without gaps) is sufficient. Space and time complexity is $O(n)$.
- unbounded gaps:* The gaps in this version are unbounded. (we seek only one occurrence)
- Solution: Just scan from left to right the string (time and space complexity is $O(n)$). If we want (δ, γ) -approximate matching then we have to resort to the algorithm for α -bounded gaps setting $\alpha=n+1$ or $\alpha=\infty$ (time and space complexity is $O(nm)$).




δ -occurrence minimizing total difference of gaps

We seek a δ -occurrence of p in t minimizing $\sum_{1 \leq i \leq m-2} G_i$, where $G_i = |g_i - g_{i+1}|$. We reduce this minimization problem to the shortest path problem on a graph:

1. Construct graph $H = (V, E)$. The set of nodes V is constructed by creating nodes $v_{i,j}$ ($1 \leq i \leq m$, $1 \leq j \leq n$) whenever $p_i =_{\delta} t_j$. An edge exists between $v_{i,j}$ and $v_{i',j'}$ if $i' = i + 1$ and $j' > j$. This edge has weight equal to $j' - j - 1$. These edges encode the occurrences of the pattern p in t . Link node s to all nodes $v_{1,j}$ and node d to all nodes $v_{m,j}$.
2. By contracting two nodes connected by an edge in a single node we get the graph H' that encodes the differences of consecutive gaps. The shortest path from s to d gives us the appropriate occurrence of p in t .



δ -occurrence minimizing total difference of gaps (an example)



The time and space complexity of this algorithm is $O(n^2m)$.



δ -occurrence with ε -bounded difference gaps

- ✓ Problem: We seek a δ -occurrence of p in t such that $|g_i - g_{i+1}| < \varepsilon$.
- ✓ Solution: Make use of graph H' with the difference that we need not find the shortest path but just to find a path from s to d (*after removing all the edges with weight*).

The time and the space complexity is equal to $O(n^2m)$.



δ -occurrence of a set of strings with Δ -bounded gaps

✓ Problem: Assume $w_1, \dots, w_m \in \Sigma^*$. We wish to find δ -occurrences of w_i (without gaps) where the gaps between consecutive occurrences of strings w_i and w_{i+1} are bounded by Δ .

✓ Solution: Define $p = w_1 w_2 \dots w_m$. Then we abstract each w_i as a single character and continue as in α -bounded gaps with the construction of matrix D . The space and time complexity is $O(n(|w_1| + |w_2| + \dots + |w_m|))$.



Τέλος Ενότητας

Χρηματοδότηση

- Το παρόν εκπαιδευτικό υλικό έχει αναπτυχθεί στο πλαίσιο του εκπαιδευτικού έργου του διδάσκοντα.
- Το έργο «**Ανοικτά Ακαδημαϊκά Μαθήματα στο Πανεπιστήμιο Πατρών**» έχει χρηματοδοτήσει μόνο την αναδιαμόρφωση του εκπαιδευτικού υλικού.
- Το έργο υλοποιείται στο πλαίσιο του Επιχειρησιακού Προγράμματος «Εκπαίδευση και Δια Βίου Μάθηση» και συγχρηματοδοτείται από την Ευρωπαϊκή Ένωση (Ευρωπαϊκό Κοινωνικό Ταμείο) και από εθνικούς πόρους.



Σημειώματα

Σημείωμα Ιστορικού Εκδόσεων Έργου

Το παρόν έργο αποτελεί την έκδοση 1.0.



Σημείωμα Αναφοράς

Copyright Πανεπιστήμιο Πατρών, Μακρής Χρήστος, Περδικούρη Αικατερίνη.
«Εισαγωγή στη Βιοπληροφορική. Αλγόριθμοι κατηγοριοποίησης βιολογικών δεδομένων». Έκδοση: 1.0. Πάτρα 2015. Όλες οι εικόνες έχουν δημιουργηθεί από την κυρία Περδικούρη Αικατερίνη, εκτός αν αναφέρεται διαφορετικά.
Διαθέσιμο από τη δικτυακή διεύθυνση:

<https://eclass.upatras.gr/courses/CEID1047/>



Σημείωμα Αδειοδότησης

Το παρόν υλικό διατίθεται με τους όρους της άδειας χρήσης Creative Commons Αναφορά, Μη Εμπορική Χρήση Παρόμοια Διανομή 4.0 [1] ή μεταγενέστερη, Διεθνής Έκδοση. Εξαιρούνται τα αυτοτελή έργα τρίτων π.χ. φωτογραφίες, διαγράμματα κ.λ.π., τα οποία εμπεριέχονται σε αυτό και τα οποία αναφέρονται μαζί με τους όρους χρήσης τους στο «Σημείωμα Χρήσης Έργων Τρίτων».



[1] <http://creativecommons.org/licenses/by-nc-sa/4.0/>

Ως **Μη Εμπορική** ορίζεται η χρήση:

- που δεν περιλαμβάνει άμεσο ή έμμεσο οικονομικό όφελος από την χρήση του έργου, για το διανομέα του έργου και αδειοδόχο
- που δεν περιλαμβάνει οικονομική συναλλαγή ως προϋπόθεση για τη χρήση ή πρόσβαση στο έργο
- που δεν προσπορίζει στο διανομέα του έργου και αδειοδόχο έμμεσο οικονομικό όφελος (π.χ. διαφημίσεις) από την προβολή του έργου σε διαδικτυακό τόπο

Ο δικαιούχος μπορεί να παρέχει στον αδειοδόχο ξεχωριστή άδεια να χρησιμοποιεί το έργο για εμπορική χρήση, εφόσον αυτό του ζητηθεί.

Διατήρηση Σημειωμάτων

Οποιαδήποτε αναπαραγωγή ή διασκευή του υλικού θα πρέπει να συμπεριλαμβάνει:

- το Σημείωμα Αναφοράς
- το Σημείωμα Αδειοδότησης
- τη δήλωση Διατήρησης Σημειωμάτων
- το Σημείωμα Χρήσης Έργων Τρίτων (εφόσον υπάρχει)

μαζί με τους συνοδευόμενους υπερσυνδέσμους.

