

Bioinformatik

Lokale Alignierung
Gapkosten



Silke Trißl / Ulf Leser
Wissensmanagement in der
Bioinformatik



Inhalt dieser Vorlesung

- Ähnlichkeit
- Lokales und globales Alignment
- Gapped Alignment

Ähnlichkeit

- Welche Frage will man eigentlich beantworten?
 - Wie weit entfernt sind diese beiden Sequenzen?
 - Wie ähnlich sind sich zwei Sequenzen?
- Editabstand berechnet den (einen) Abstand
 - Großer Abstand – geringe Ähnlichkeit
- Wir können die Sequenzähnlichkeit auch direkt berechnen
 - Intuitives Maß – je ähnlicher, desto höher ist die Wahrscheinlichkeit für ähnliche Funktion
- Dabei werden wir langsam differenzierter
 - Ähnlichkeit einzelner Basen / Aminosäuren
 - Ähnliche Moleküle – positive Werte
 - Unähnliche Moleküle – negative Werte
 - Individuelle Kosten für InsDel einer Base

Formal

- Definition

Gegeben Alphabet $\Sigma' = \Sigma \cup \{ \text{_, } \}$, Strings A,B über Σ' mit $|A| = |B| = n$

- Eine *Scoringfunktion* ist eine Funktion $s: \Sigma' \times \Sigma' \rightarrow \text{Integer}$
 - Anderer Name: Substitutionsmatrix
- Die *Ähnlichkeit* von A,B bzgl. der Scoringfunktion s ist

$$\text{sim}(A, B) = \sum_{i=1}^n s(A[i], B[i])$$

- Bemerkung

- Zur Anwendung für zwei Sequenzen A,B wählen wir ein Alignment und berechnen dann die Ähnlichkeit der beiden Zeilen zueinander
 - Also mit den eingefügten InsDels
- Wir suchen natürlich wieder das/die Alignment(s) mit dem höchsten Ähnlichkeitswert

Beispiel

$$\Sigma' = \{A, C, G, T, _\}$$

	A	C	G	T	_
A	4	-2	-2	-2	-2
C		4	-2	-2	0
G			4	-1	0
T				4	-2
_					0

AC_GTC
AGGT_C

= 3

ACGTC
AGGTC

= 14

A_CGTC
AG_GTC

= 16

Berechnung

- Gleiches Prinzip wie zur Berechnung des Editabstands
- Nur kleine Veränderungen

$$d(i,0) = \sum_{k=1}^i s(A[k], _) \quad d(0,j) = \sum_{k=1}^j s(_, B[k])$$

$$d(i,j) = \max \left\{ \begin{array}{l} d(i, j-1) + s(_, B[j]) \\ d(i-1, j) + s(A[i], _) \\ d(i-1, j-1) + s(A[i], B[j]) \end{array} \right\}$$

Beispiel

Abstand
(Ins/del/Repl: 1,
Match: 0)

		A	G	G	T	C
	0	1	2	3	4	5
A	1	0	1	2	3	4
G	2	1	0	1	2	3
T	3	2	1	1	1	2
C	4	3	2	2	2	1
C	5	4	3	3	3	2

Ähnlichkeit

	A	G	T	C
A	4	-1	-1	-1
G		4	-1	-1
T			4	-1
C				4
_	-3	-3	-3	-3

	A	G	G	T	C	
	0	-3	-6	-9	-12	-15
A	-3	4	1	-2	-5	-8
G	-6	1	8	5		
T	-9					
C	-12					
C	-15					

Lokales und globales Alignment

- Bisher: **Globale Alignments**
 - Beide Sequenzen werden komplett betrachtet
- Das entspricht oft nicht der biologischen Frage
 - Funktion wird nur durch manche Sequenzblöcke bestimmt (Gene, Exons, Proteindomänen, ...)
- Wir suchen meistens **ähnliche Teilsequenzen**
 - Funktionstragende Sequenzblöcke
 - „**Lokale**“ Alignments

The diagram shows two horizontal rows of DNA sequence. The top row is ACCCTATCGATAAGCTCGATAAAATACCGACCAAGTAT. The bottom row is AGGAGTCGATAATACATAATAAGAGATAAGAAATAATTGATG. A segment from position 6 to 11 in the top sequence (TCGATAA) and a segment from position 7 to 12 in the bottom sequence (TCGATAATA) are highlighted in orange, indicating a local alignment.


The diagram shows two horizontal rows of DNA sequence. The top row is ACCCTATCGATA--GC-TAGAAAGCTCGATAATACCGACCAAGTAT-. The bottom row is A-GGAGTCGATAATACATAATAAG-A-GATAAGAAATA-TTGATG. Vertical black lines connect matching nucleotides between the two rows. The top sequence has a gap represented by three dashes (- - -) and the bottom sequence has a gap represented by one dash (-).

Lokale Alignments

- Definition. Gegeben zwei Strings A, B .
 - Seien a, b Substrings mit $a \subseteq A, b \subseteq B$ so dass

$$sim(a, b) = \max_{\forall a' \in A, b' \in B} (sim(a', b'))$$

- Das vom (globalen) Alignment von a und b induzierte Alignment von A und B heißt lokales Alignment von A und B
 - Der lokale Ähnlichkeitsscore $dist_{local}(A, B) = sim(a, b)$
- Bemerkung
 - Unempfindlich gegen unterschiedliche lange Strings
 - Beispiel
 - Lokales A. findet den identischen Substring



Smith-Waterman Algorithmus



- Smith, Waterman: „Identification of common molecular subsequences“, J. Mol. Bio 147, 1981
- Grundidee
 - Geringfügige Veränderung des Algorithmus für globales Alignment
 - Funktioniert nur mit Ähnlichkeit, nicht mit Abstand
 - Scoring Funktion mit positiven Werten für Matches und negativen Werten für alles andere
 - Eine Reihe von Matches beim Vergleich erzeugt also sukzessive größere Ähnlichkeitswerte
 - Bei Mismatch oder InsDel wird der Wert wieder kleiner
 - Um Regionen mit hoher Ähnlichkeit zu finden, können wir alle Substringmatches mit negativem Gesamtähnlichkeit vergessen
 - Also: Statt in negative Werte zu rutschen, darf der Algorithmus auch bei 0 anfangen

Match: +1
I/R/D: -1

Beispiel

		A	T	G	T	G	G
	0	-1	-2	-3	-4	-5	-6
G				-1			
T					0		
G						1	
A							0

		A	T	G	T	G	G
	0	0	0	-3	-4	-5	-6
G				1			
T					2		
G						3	
A							0



Optimales lokales Alignment

- Theorem

Gegeben Strings A,B. Mit der folgenden Funktion $v(i,j)$, mit $0 \leq i \leq n$ und $0 \leq j \leq m$

$$v(i, j) = \max \left\{ \begin{array}{l} v(i, j - 1) + s(_, B[i]) \\ v(i - 1, j) + s(A[i], _) \\ v(i - 1, j - 1) + s(A[i], B[j]) \end{array} \right\}$$

- Gilt: $dist_{local}(A, B) = \max_{i,j}(v(i, j))$

- Traceback

- Starte beim maximalen Wert in der Matrix
- Verfolge beliebigen Pfad bis zu einer Zelle mit Wert 0

Beispiel

Match: +1
I/R/D: -1

		A	T	G	T	C	G
	0	-1	-2	-3	-4	-5	-6
A	-1	1	0	-1	-2	-3	-4
T	-2	0	2	1	0	-1	-2
G	-3	-1	1	3	2	1	0

ATGTCG
ATG ____

ATGTCG
AT ____ G

ATGTCG
A ____ T_G

➤ Drei Lösungen, alle mit gleicher Güte

		A	T	G	T	C	G
	0	0	0	0	0	0	0
A	0	1	0	0	0	0	0
T	0	0	2	1	1	0	0
G	0	0	1	3	2	1	0

ATGTCG
ATG ____

➤ Eine Lösung – das lokale Alignment

Wann lokales, wann globales Alignment

- Globales Alignment
 - Genauer Vergleich ähnlicher Sequenzen
 - Z.B. Charakterisierung von Protein-Familien
 - Z.B. Bestimmung einer Consensus-Sequenz für MSA
- Lokales Alignment
 - Finden der interessanten Regionen in unbekannten Sequenzen
 - Z.B. unterschiedliche Spezies, unterschiedliche Gene, ...
 - Finden konservierter (=funktionaler) Subsequenzen
 - Erster Schritt zur Proteinfamilie; danach g. A. innerhalb der Familie
 - Finden konservierter Bereiche
 - Untersuchung von evolutionären Prozessen

Inhalt dieser Vorlesung

- Ähnlichkeit
- Lokales und globales Alignment
- Gapped Alignment
 - Gap = Loch = Zusammenhänge Folge von Spaces = Insertions bzw. Deletions
 - Bisher zählt jedes Space einzeln
 - Ist das immer das richtige Modell?

Gaps

- Evolution besteht nicht nur aus Punktmutationen
- Oft werden **ganze Blöcke** verschoben
 - Beispiele
 - Crossing-Over während Meiose (geschlechtliche Zellteilung)
 - „Versehentliche“ Duplikation von Sequenzen
 - Transposable Elements
- Dazwischen: lange Reihen von Inserts / Deletions
- Nur die „guten“ Blöcke sind relevant, die Zwischenräume nicht
 - **Exons und Introns** unterliegen unterschiedlichem Selektionsdruck
 - Proteine setzen sich aus „**active sites**“ und variablen Zwischensequenzen zusammen


Bewertung von Gaps

- Gesucht: **Gapscorefunktionen**, die Gaps unterschiedlicher Länge bei der Berechnung der Sequenzähnlichkeit flexibel bewerten können
- Sei $w(k)$ der Score eines Gaps der Länge k
- Folgende Funktionsklassen
 - **Konstanter** Gapscore c
 - $w(k) = c$
 - Score unabhängig von Gaplänge
 - **Linearer** Gapscore mit Kosten für Gapbeginn w_s und Gapfortsetzung w_f
 - $w(k) = w_s + w_f * k$
 - Bisheriges Modell nimmt $w_s=0$ und $w_f=1$ an
 - **Konvexer** Gapscore - Score wird nie kleiner mit wachsendem k , aber immer langsamer größer
 - $w(k) = f(k)$; mit $f'(k)>0$ und $f''(k)\leq 0$
 - Beispiel: $w = \log(k)$
 - **Beliebiger** Gapscore - Score kann wachsen, fallen, oszillieren, ...
 - $w(k) = f(k)$; mit $f(k)$ beliebig


Klassen von Gapscorefunktionen




- Konstanter Gapscore



- Linearer Gapscore



- Konvexer Gapscore



- Beliebiger Gapscore

Auswirkungen auf Berechnung

- Je **flexibler die Scorefunktion**, desto komplexer die Berechnung
 - Konstant oder linear: $O(nm)$
 - Konvex: $O(nm \log m)$
 - Beliebig: $O(nm^2 + n^2m)$