

# Sequenzvergleiche ohne Alignments durch lokales Dekodieren von Sequenzen

Christian Otto

(16. Juli 2007)

# Inhalt

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschießende Bemerkungen

## 1 Grundidee

## 2 Naiver Algorithmus

- Definitionen
- Lokales N-Dekodieren
- Ermittlung der Distanzmatrix
- Aussagefähigkeit der Distanzen

## 3 Verbesserungen

- Verbesserung der Komplexität
- Erweiterung des evolutionären Modells

## 4 Leistung bei HIV/SIV Subtyping

- Kurze Sequenzen: HIV/SIV gag, pol, env und nef
- Non-coding Long Terminal Repeats (LTR)

## 5 Abschließende Bemerkungen

# Alignments

- beruhend auf Editieroperation (Substitution, Deletion, Insertion), schlechte Einschätzung von Deletionen
- Löschen von mehrdeutigen Regionen bei multiplen Alignments  
→ Informationsverlust
- oft Vernachlässigung von Permutationen und Inversionen
- Verwendung von manuelles Alignment (Expert Editing) zum Berücksichtigen von mehrdeutige Regionen  
→ großer Aufwand, Problem der Reproduzierbarkeit

## Idee der Sequenzvergleiche ohne Alignments:

- intuitiver Ansatz: Nukleotidhäufigkeiten vergleichen, da Sequenzen mit signifikant unterschiedlichen Nukleotidzusammensetzungen nicht nah verwandt sein können  
→ aber: nicht nah verwandte Sequenzen können gleiche Nukleotidhäufigkeiten besitzen

## Idee der Sequenzvergleiche ohne Alignments:

- intuitiver Ansatz: Nukleotidhäufigkeiten vergleichen, da Sequenzen mit signifikant unterschiedlichen Nukleotidzusammensetzungen nicht nah verwandt sein können  
→ aber: nicht nah verwandte Sequenzen können gleiche Nukleotidhäufigkeiten besitzen
- nächster Schritt: N-Wörter (Teilsequenzen der Länge N) zwischen Sequenzen vergleichen, um daraus Ähnlichkeiten zu berechnen  
aber: N-Wörter entweder identisch oder unterschiedlich

## Idee der Sequenzvergleiche ohne Alignments:

- intuitiver Ansatz: Nukleotidhäufigkeiten vergleichen, da Sequenzen mit signifikant unterschiedlichen Nukleotidzusammensetzungen nicht nah verwandt sein können  
→ aber: nicht nah verwandte Sequenzen können gleiche Nukleotidhäufigkeiten besitzen
- nächster Schritt: N-Wörter (Teilsequenzen der Länge N) zwischen Sequenzen vergleichen, um daraus Ähnlichkeiten zu berechnen  
aber: N-Wörter entweder identisch oder unterschiedlich
- Kompensierung durch Betrachtung von nicht perfekt identischen N-Wörtern (die Modelle und Algorithmen von diesem Vortrag berücksichtigen dies noch nicht)

Um evolutionäre Informationen aus mehrdeutigen Regionen zu gewinnen und nicht auf manuelles Alignment angewiesen zu sein, wurde dann die Idee vom lokalen Dekodieren vom Grad  $N$  von Sequenzen entwickelt:

- beruhend auf Vergleichen zwischen überlappenden Wörtern der Länge  $N$
- Übereinstimmungen von solchen Teilwörter zwischen verschiedenen Sequenzen entsprechen konzeptionell homologen Blöcken zwischen diesen Sequenzen  
→ Sequenzvergleiche und somit Erstellung eines Verwandtschaftsbaumes basierend auf dieser Idee

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

# Definition der Relation $\overset{k}{\underset{\curvearrowright}{\sim}}_N$

Sei  $s$  eine Sequenz und  $N \in \mathbb{N}$ ,  $N > 0$ .

Dann ist die Relation  $(\overset{k}{\underset{\curvearrowright}{\sim}}_N)_{-1 \leq k < N}$  für alle Paare von Positionen  $(i, j)$  von  $s$  definiert durch:

- $i \overset{-1}{\underset{\curvearrowright}{\sim}}_N j \Leftrightarrow i = j$
- Für  $0 \leq k < N$ :  

$$i \overset{k}{\underset{\curvearrowright}{\sim}}_N j \Leftrightarrow \exists l, 0 \leq l \leq k: s_{[i-l, i-l+N-1]} = s_{[j-l, j-l+N-1]}.$$

Für alle Zahlen  $-1 \leq k < N$  sei dann  $\overset{k}{\underset{\curvearrowright}{\sim}}_N$  die transitive Hülle der Relation  $\overset{k}{\underset{\curvearrowright}{\sim}}_N$ .

Aus der Relation  $\overset{k}{\underset{N}{\smile}}$  folgende Aussagen:

①  $i \overset{k-1}{\underset{N}{\smile}} j \Rightarrow i \overset{k}{\underset{N}{\smile}} j$

Aus der Relation  $\overset{k}{\underset{N}{\simeq}}$  folgende Aussagen:

- 1  $i \overset{k-1}{\underset{N}{\simeq}} j \Rightarrow i \overset{k}{\underset{N}{\simeq}} j$
- 2  $i \overset{k-1}{\underset{N}{\simeq}} j \Rightarrow i + 1 \overset{k}{\underset{N}{\simeq}} j + 1$

Aus der Relation  $i \overset{k}{\underset{N}{\smile}} j$  folgende Aussagen:

$$① \quad i \overset{k-1}{\underset{N}{\smile}} j \Rightarrow i \overset{k}{\underset{N}{\smile}} j$$

$$② \quad i \overset{k-1}{\underset{N}{\smile}} j \Rightarrow i + 1 \overset{k}{\underset{N}{\smile}} j + 1$$

$$③ \quad i \overset{k}{\underset{N}{\smile}} j \Rightarrow S_{[i, i-k+N-1]} = S_{[j, j-k+N-1]}$$

Aus der Relation  $\overset{k}{\underset{\sim}{N}}$  folgende Aussagen:

$$\textcircled{1} \quad i \overset{k-1}{\underset{\sim}{N}} j \Rightarrow i \overset{k}{\underset{\sim}{N}} j$$

$$\textcircled{2} \quad i \overset{k-1}{\underset{\sim}{N}} j \Rightarrow i + 1 \overset{k}{\underset{\sim}{N}} j + 1$$

$$\textcircled{3} \quad i \overset{k}{\underset{\sim}{N}} j \Rightarrow s_{[i, i-k+N-1]} = s_{[j, j-k+N-1]}$$

Für alle  $-1 \leq k < N$  ist die Relation  $\overset{k}{\underset{\sim}{N}}$  eine Äquivalenzrelation (unter der Annahme, dass  $|s| \geq N$  gilt).

$\Delta_k$  sei die Menge der zur Relation  $\overset{k}{\underset{\sim}{N}}$  gehörigen Äquivalenzklassen.

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - **Lokales N-Dekodieren**
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

# Verwandtschaft zwischen Sequenzpositionen

- Es gilt  $i \stackrel{N-1}{\sim} j$ , wenn ein überlappendes N-Wort über Position  $i$  und  $j$  übereinstimmt, wobei  $i$  und  $j$  in diesem Wort jeweils an der gleichen Position steht.

Beispiel:

Sequenz	...tagacacta...	tccacactg...
Menge von überlappenden N-Wörtern	i tagac agaca gacac <b>acact</b> cacta	j tccac ccaca cacac <b>acact</b> cactg

# Verwandtschaft zwischen Sequenzpositionen

- Es gilt  $i \overset{N-1}{\smile} j$ , wenn ein überlappendes N-Wort über Position  $i$  und  $j$  übereinstimmt, wobei  $i$  und  $j$  in diesem Wort jeweils an der gleichen Position steht.

Beispiel:

Sequenz	...tagacacta...	tccacactg...
Menge von	tagac	tccac
überlappenden	agaca	ccaca
N-Wörtern	gacac	cacac
	acact	acact
	cacta	cactg

- Zwei Sequenzpositionen  $a$ ,  $b$  sind genau dann verwandt, wenn  $a \overset{N-1}{\smile} b$  gilt

# Verwandtschaft zwischen Sequenzpositionen

- Es gilt  $i \overset{N-1}{\smile}_N j$ , wenn ein überlappendes N-Wort über Position  $i$  und  $j$  übereinstimmt, wobei  $i$  und  $j$  in diesem Wort jeweils an der gleichen Position steht.

Beispiel:

Sequenz	...tagacacta...	tccacactg...
Menge von	tagac	tccac
überlappenden	agaca	ccaca
N-Wörtern	gacac	cacac
	acact	acact
	cacta	cactg

- Zwei Sequenzpositionen  $a$ ,  $b$  sind genau dann verwandt, wenn  $a \overset{N-1}{\smile}_N b$  gilt  
d.h. es gibt Positionen  $k_0, \dots, k_n$  mit  $k_0 = a$ ,  $k_n = b$  und  
 $\forall i \in \{0, \dots, n-1\} : k_i \overset{N-1}{\smile}_N k_{i+1}$

# Ermittlung der Äquivalenzklassen

- a) Menge der N-Wörter jeder Sequenzposition ermitteln und miteinander vergleichen  
⇒ Finden von Relationen  $i \underset{N}{\overset{N-1}{\smile}} j$

# Ermittlung der Äquivalenzklassen

- a) Menge der N-Wörter jeder Sequenzposition ermitteln und miteinander vergleichen  
 ⇒ Finden von Relationen  $i \underset{N}{\overset{N-1}{\curvearrowright}} j$
- b) Transitiven Abschluss der Relation  $\underset{N}{\overset{N-1}{\curvearrowright}}$  und Äquivalenzklassen bilden

# Ermittlung der Äquivalenzklassen

- a) Menge der N-Wörter jeder Sequenzposition ermitteln und miteinander vergleichen  
 ⇒ Finden von Relationen  $i \stackrel{N-1}{\sim} j$
- b) Transitiven Abschluss der Relation  $\stackrel{N-1}{\sim}$  und Äquivalenzklassen bilden

Beispiel:

```

a) >seq1      CATTG TCCGC TGGAC CACAC CTTGT CCCTA
    >seq2      CACTT GGAGA CATAAC CATGC
    >seq3      CACTT CTCTC CTGGA CCTCC
  
```

```

seq1, 11  CCGCTGGAC
          CCGCT
          CGCTG
          GCTGG
          CTGGA
          TGGAC
  
```

```

seq2, 5   CACTTGGAC
          CACTT
          ACTTG
          CTTGG
          TTGGA
          TGGAC
  
```

```

seq3, 5   CACTTCTTT
          CACTT
          ACTTC
          CTCTC
          TTCTT
          TCTTT
  
```

```

seq3, 12  TTCCTGGAC
          TTCCT
          TCCTG
          CCTGG
          CTGGA
          TGGAC
  
```

```

b) class_1 : T0
    seq1 3  CATTGTC
    seq1 22 CACCTGTC
class_2 : T1
    seq1 4  CATTGTCC
    seq1 23 ACCTGTCC
class_3 : G0
    seq1 5  CATTGTCCG
    seq1 24 CCTTGTCCC
class_4 : T2
    seq1 6  ATTGTCGGC
    seq1 25 CTTGTCCCT
class_5 : C0
    seq1 7  TTGTCGCGT
    seq1 26 TTGTCCTA
class_6 : C1
    seq1 8  TGTCGCGTG
    seq1 27 TGTCCTA
class_7 : C2
    seq1 10 TCCGCTGGA
    seq3 11 TTTCCTGGA
class_8 : T3
    seq1 11 CCGCTGGAC
    seq2 5  CACTTGGAC
    seq3 5  CACTTCTTT
    seq3 12 TTCCCTGGAC
class_9 : G1
    seq1 12 CGCTGGACC
    seq2 6  ACTTGGACA
    seq3 13 TCCTGGACC

class_10 : G2
    seq1 13 GCTGGACCA
    seq2 7  CTTGGACAC
    seq3 14 CCTGGACCT
class_11 : A0
    seq1 14 CTGGACCAC
    seq2 8  TTGGACACA
    seq3 15 CTGGACCTC
class_12 : C3
    seq1 15 TGGACCACA
    seq2 9  TGGACACAT
    seq3 16 TGGACCTCC
class_13 : C4
    seq1 16 GGACCACAC
    seq3 17 GGACCCTCC
class_14 : C5
    seq2 1  CACTT
    seq3 1  CACTT
class_15 : A1
    seq2 2  CACTTGG
    seq3 2  CACTTTC
class_16 : C6
    seq2 3  CACTTGG
    seq3 3  CACTTCT
class_17 : T4
    seq2 4  CACTTGGGA
    seq3 4  CACTTCTT

```

# Lokales N-Dekodieren

- c) Äquivalenzklassen auf Zustände abbilden  
(Positionen, die in einelementigen Klassen auftauchen, werden auf dem identischen Symbol abgebildet und nicht weiter betrachtet.)  
⇒ Dies wird als lokales N-Dekodieren der Sequenz bezeichnet (analog zu Hidden Markov Modell).

# Lokales N-Dekodieren

- c) Äquivalenzklassen auf Zustände abbilden  
 (Positionen, die in einelementigen Klassen auftauchen, werden auf dem identischen Symbol abgebildet und nicht weiter betrachtet.)  
 ⇒ Dies wird als lokales N-Dekodieren der Sequenz bezeichnet (analog zu Hidden Markov Modell).

Beispiel:

```
c) >seq1  C A T0T1G0T2C0C1G C2T3G1G2A0C3C4A C A C C T0T1G0T2C0C1C T A
>seq2  C5A1C6T4T3G1G2A0C3A C A T A C C A T G C
>seq3  C5A1C6T4T3C T T T C C2T3G1G2A0C3C4T C C
```

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - **Ermittlung der Distanzmatrix**
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

- d) Erstellen einer Liste mit Anzahl Vorkommen jedes Zustandes (der einer Äquivalenzklasse entspricht) je Sequenz

- d) Erstellen einer Liste mit Anzahl Vorkommen jedes Zustandes (der einer Äquivalenzklasse entspricht) je Sequenz

Beispiel:

d)	seq1	seq2	seq3
T3	1	1	2
T4	0	1	1
A0	1	1	1
A1	0	1	1
G1	1	1	1
G2	1	1	1
C2	1	0	1
C3	1	1	1
C4	1	0	1
C5	0	1	1
C6	0	1	1

(T0, T1, T2, G0, C0 and C1 are only repeated in seq1, two times each)

# Berechnung der Distanzmatrix

Seien Zustände  $x_1, \dots, x_n$  mit  $n \in \mathbb{N}$  gegeben.

Nun sei  $|u|_{x_i}$  die Anzahl von Vorkommen des Zustandes  $x_i$  in der Sequenz  $u$  und  $|u|$  die Länge der Sequenz  $u$ .

# Berechnung der Distanzmatrix

Seien Zustände  $x_1, \dots, x_n$  mit  $n \in \mathbb{N}$  gegeben.

Nun sei  $|u|_{x_i}$  die Anzahl von Vorkommen des Zustandes  $x_i$  in der Sequenz  $u$  und  $|u|$  die Länge der Sequenz  $u$ .

- e) Berechnen der Ähnlichkeiten  $\text{sim}(u, v)$  zwischen Sequenzen  $u$  und  $v$  durch:

$$\text{sim}(u, v) = \sum_{i=1}^n \min(|u|_{x_i}, |v|_{x_i})$$

# Berechnung der Distanzmatrix

Seien Zustände  $x_1, \dots, x_n$  mit  $n \in \mathbb{N}$  gegeben.

Nun sei  $|u|_{x_i}$  die Anzahl von Vorkommen des Zustandes  $x_i$  in der Sequenz  $u$  und  $|u|$  die Länge der Sequenz  $u$ .

- e) Berechnen der Ähnlichkeiten  $\text{sim}(u, v)$  zwischen Sequenzen  $u$  und  $v$  durch:

$$\text{sim}(u, v) = \sum_{i=1}^n \min(|u|_{x_i}, |v|_{x_i})$$

Normalisierung und Berechnung der Distanzen durch:

$$\text{dist}(u, v) = 1 - \frac{\text{sim}(u, v)}{\min(|u|, |v|)}$$

## Beispiel:

d)

	seq1	seq2	seq3
T3	1	1	2
T4	0	1	1
A0	1	1	1
A1	0	1	1
G1	1	1	1
G2	1	1	1
C2	1	0	1
C3	1	1	1
C4	1	0	1
C5	0	1	1
C6	0	1	1

## e) Similarities

	seq2	seq3
seq1	5	7
seq2		9

## Distances

	seq2	seq3
seq1	0.75	0.65
seq2		0.55

## Beispiel:

d)

	seq1	seq2	seq3
T3	1	1	2
T4	0	1	1
A0	1	1	1
A1	0	1	1
G1	1	1	1
G2	1	1	1
C2	1	0	1
C3	1	1	1
C4	1	0	1
C5	0	1	1
C6	0	1	1

## e) Similarities

	seq2	seq3
seq1	5	7
seq2		9

## Distances

	seq2	seq3
seq1	0.75	0.65
seq2		0.55

⇒ Erstellung eines Verwandtschaftsbaumes möglich  
(z.B. Neighbor-Joining-Tree)

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren
- Idee: Vergleich mit Distanzwerten von randomisierten Sequenzen  $\Rightarrow$  Bootstrap

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren
- Idee: Vergleich mit Distanzwerten von randomisierten Sequenzen  $\Rightarrow$  Bootstrap

## Allgemeine Vorgehensweise bei Bootstrap

- 1 Erstellen von Bootstrapsamples aus einer Stichprobe (Resampling)

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren
- Idee: Vergleich mit Distanzwerten von randomisierten Sequenzen  $\Rightarrow$  Bootstrap

## Allgemeine Vorgehensweise bei Bootstrap

- 1 Erstellen von Bootstrapsamples aus einer Stichprobe (Resampling)
- 2 Berechnung einer bestimmten Größe aus dem Sample

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren
- Idee: Vergleich mit Distanzwerten von randomisierten Sequenzen  $\Rightarrow$  Bootstrap

## Allgemeine Vorgehensweise bei Bootstrap

- 1 Erstellen von Bootstrapsamples aus einer Stichprobe (Resampling)
- 2 Berechnung einer bestimmten Größe aus dem Sample
- 3 Iteration dieser Schritte  
 $\Rightarrow$  Ergebnis: Verteilung der Größe aus den Samples

# Bootstrap

- Distanzmaß ist zunächst nicht aussagekräftig bei neuem Verfahren
- Idee: Vergleich mit Distanzwerten von randomisierten Sequenzen  $\Rightarrow$  Bootstrap

## Allgemeine Vorgehensweise bei Bootstrap

- 1 Erstellen von Bootstrapsamples aus einer Stichprobe (Resampling)
- 2 Berechnung einer bestimmten Größe aus dem Sample
- 3 Iteration dieser Schritte  
 $\Rightarrow$  Ergebnis: Verteilung der Größe aus den Samples

$\Rightarrow$  p-Wert Schätzung möglich

# Anwendung des Bootstraps auf diesen Sachverhalt

Sei Distanz  $\text{dist}(u, v)$  der Sequenzen  $u$  und  $v$  gegeben.

- 1  $u$  und  $v$  resampeln (mit Zurücklegen aus der alten Sequenz ziehen und neue Sequenz gleicher Länge erstellen)  
⇒ neue Sequenzen  $u^*$ ,  $v^*$

# Anwendung des Bootstraps auf diesen Sachverhalt

Sei Distanz  $\text{dist}(u, v)$  der Sequenzen  $u$  und  $v$  gegeben.

- 1  $u$  und  $v$  resampeln (mit Zurücklegen aus der alten Sequenz ziehen und neue Sequenz gleicher Länge erstellen)  
 $\Rightarrow$  neue Sequenzen  $u^*, v^*$
- 2  $\text{dist}(u^*, v^*)$  über N-lokales Dekodieren berechnen

# Anwendung des Bootstraps auf diesen Sachverhalt

Sei Distanz  $\text{dist}(u, v)$  der Sequenzen  $u$  und  $v$  gegeben.

- 1  $u$  und  $v$  resampeln (mit Zurücklegen aus der alten Sequenz ziehen und neue Sequenz gleicher Länge erstellen)  
 $\Rightarrow$  neue Sequenzen  $u^*$ ,  $v^*$
- 2  $\text{dist}(u^*, v^*)$  über N-lokales Dekodieren berechnen
- 3 mehrfache Iteration  $\Rightarrow$  Verteilung von  $\text{dist}$

# Anwendung des Bootstraps auf diesen Sachverhalt

Sei Distanz  $\text{dist}(u, v)$  der Sequenzen  $u$  und  $v$  gegeben.

- 1  $u$  und  $v$  resampeln (mit Zurücklegen aus der alten Sequenz ziehen und neue Sequenz gleicher Länge erstellen)  
 $\Rightarrow$  neue Sequenzen  $u^*$ ,  $v^*$
- 2  $\text{dist}(u^*, v^*)$  über N-lokales Dekodieren berechnen
- 3 mehrfache Iteration  $\Rightarrow$  Verteilung von  $\text{dist}$

Wenn  $\text{dist}(u, v)$  nun extrem in der Verteilung liegt (z.B. in den 2.5% niedrigsten oder höchsten Werten), dann deutet dieser Distanzwert auf keinen Zufallsbefund hin sondern besitzt Aussagekraft (z.B. starke Verwandtschaft).

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

Naiver Algorithmus ist von hoher Komplexität in CPU-Zeit.  
Problem ist die Berechnung der Äquivalenzklassen  $\Delta_{N-1}$ .  
⇒ Verbesserung auf lineare Komplexität in Zeit und Speicher  
möglich

Naiver Algorithmus ist von hoher Komplexität in CPU-Zeit.  
 Problem ist die Berechnung der Äquivalenzklassen  $\Delta_{N-1}$ .  
 $\Rightarrow$  Verbesserung auf lineare Komplexität in Zeit und Speicher  
 möglich

Dazu weitere Definitionen:

- $\nabla_k \subset \Delta_k$  ist definiert durch:

$$\delta \in \nabla_k \Leftrightarrow \delta \in \Delta_k, \exists i, j \in \delta \text{ mit } (i+1) \not\sim_N^k (j+1)$$

Naiver Algorithmus ist von hoher Komplexität in CPU-Zeit.  
 Problem ist die Berechnung der Äquivalenzklassen  $\Delta_{N-1}$ .  
 $\Rightarrow$  Verbesserung auf lineare Komplexität in Zeit und Speicher  
 möglich

Dazu weitere Definitionen:

- $\nabla_k \subset \Delta_k$  ist definiert durch:

$$\delta \in \nabla_k \Leftrightarrow \delta \in \Delta_k, \exists i, j \in \delta \text{ mit } (i+1) \not\sim_N^k (j+1)$$

- Die Abbildung  $F_k: \Delta_k \rightarrow \Delta_{k+1}$  ist definiert durch:

$$F_k(\gamma) = \delta \Leftrightarrow \gamma \in \Delta_k, \delta \in \Delta_{k+1}, \forall i \in \gamma : i+1 \in \delta$$

Man nennt  $\delta$  dann k-Nachfolger von  $\gamma$ .

Naiver Algorithmus ist von hoher Komplexität in CPU-Zeit.  
 Problem ist die Berechnung der Äquivalenzklassen  $\Delta_{N-1}$ .  
 $\Rightarrow$  Verbesserung auf lineare Komplexität in Zeit und Speicher  
 möglich

Dazu weitere Definitionen:

- $\nabla_k \subset \Delta_k$  ist definiert durch:

$$\delta \in \nabla_k \Leftrightarrow \delta \in \Delta_k, \exists i, j \in \delta \text{ mit } (i+1) \not\sim_N^k (j+1)$$

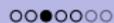
- Die Abbildung  $F_k: \Delta_k \rightarrow \Delta_{k+1}$  ist definiert durch:

$$F_k(\gamma) = \delta \Leftrightarrow \gamma \in \Delta_k, \delta \in \Delta_{k+1}, \forall i \in \gamma : i+1 \in \delta$$

Man nennt  $\delta$  dann k-Nachfolger von  $\gamma$ .

### Funktionsweise des verbesserten Algorithmus

- Ermittlung von  $\Delta_{-1}$ ,  $\Delta_0$ ,  $\nabla_0$  und  $F_{-1}$
- Iterative Berechnung von  $\Delta_k$ ,  $\nabla_k$  und  $F_{k-1}$  aus  $\Delta_{k-1}$ ,  $\nabla_{k-1}$  und  $F_{k-2}$  für  $0 < k < N-1$   
 $\Rightarrow \Delta_{N-1}$



# Ermittlung von $\Delta_0$ , $\nabla_0$ und $F_{-1}$

Gegeben sei die Sequenz  $s$ .

Beispiel: ( $N=2$ )

```
positions : 1 2 3 4 5 6 7 8 9 10 11 12 13 14  
s          = a g a c c a a g c a a g c c
```

# Ermittlung von $\Delta_0$ , $\nabla_0$ und $F_{-1}$

Gegeben sei die Sequenz  $s$ .

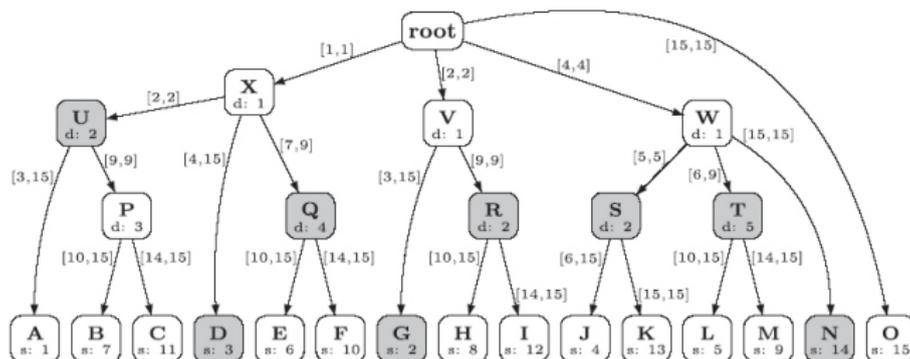
Beispiel: ( $N=2$ )

positions : 1 2 3 4 5 6 7 8 9 10 11 12 13 14

$s = \text{agaccaagcaagcc}$

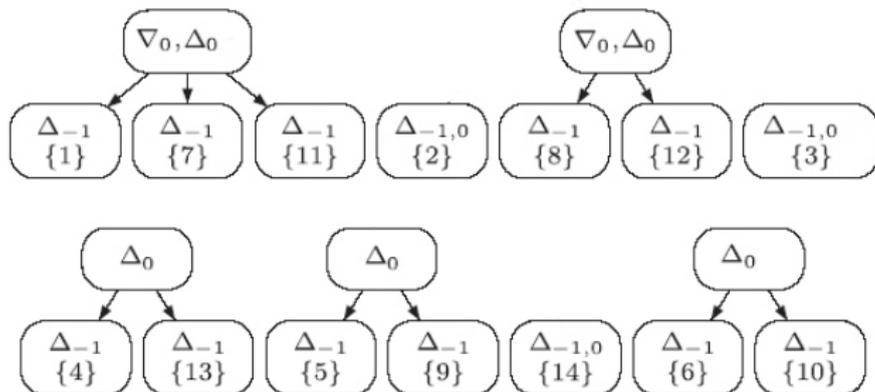
## 1. Erstellung des Suffixbaumes aus der Sequenz $s$

Beispiel:



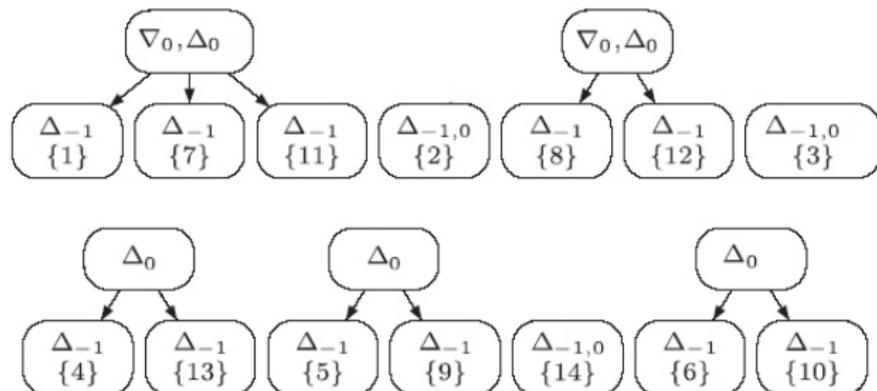
## 2. Ablesen von $\Delta_0$ und $\nabla_0$

Beispiel:



## 2. Ablesen von $\Delta_0$ und $\nabla_0$

Beispiel:



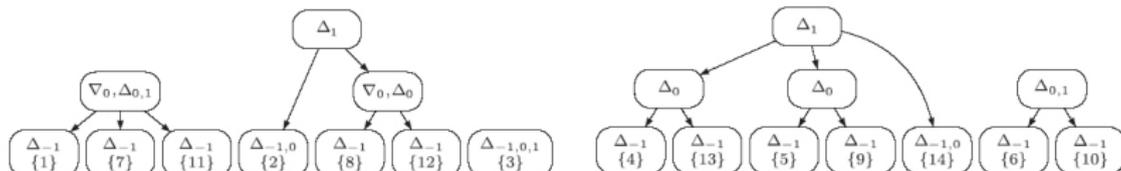
## 3. Erstellen der Funktion $F_{-1}$

#### 4. Iteration (detaillierter siehe Handout):

Für jedes Element aus  $\nabla_{k-1}$  wird ein neues Element in  $\nabla_k$  erstellt, falls kein Nachfolger gesetzt ist.

Kinderelemente und Nachfolgerverweise werden dann entsprechend gesetzt.

Beispiel:

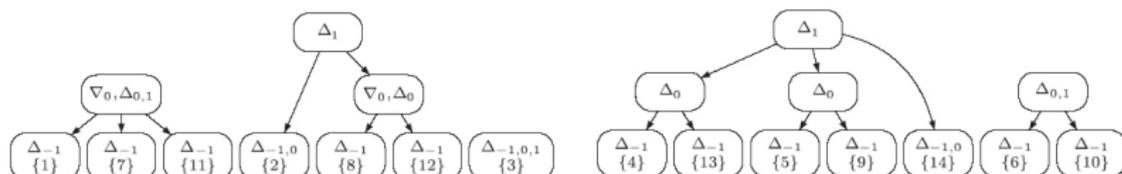


#### 4. Iteration (detaillierter siehe Handout):

Für jedes Element aus  $\nabla_{k-1}$  wird ein neues Element in  $\nabla_k$  erstellt, falls kein Nachfolger gesetzt ist.

Kinderelemente und Nachfolgerverweise werden dann entsprechend gesetzt.

Beispiel:



#### Bemerkungen zum Algorithmus:

- beruhend auf einigen theoretischen Sätzen zu  $\Delta$ ,  $\nabla$  und  $F$  [2]
- Anwendung auf multiple Alignments durch Aneinanderketten der Sequenzen zu einer Sequenz mit einzigartigen voneinander unterschiedlichen Trennsymbolen zwischen den einzelnen Sequenzen

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

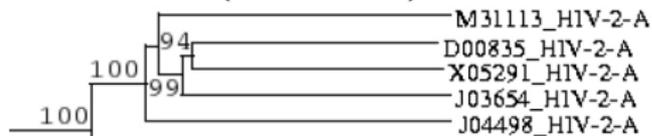
# Optionen zur Erweiterung

- Möglichkeit auch nicht perfekte Übereinstimmungen zu berücksichtigen
- Inversionen berücksichtigen:  
Invertierte Strings in Menge von überlappenden N-Wörtern übernehmen
- weitere Möglichkeiten wären denkbar  
(ggf. Permutationen betrachten),  
aber: Rechenzeit wird dadurch erhöht

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschießende Bemerkungen

- Anwendung des N-lokales Dekodierens auf 70 HIV/SIV Genomen (davon 4 unvollständige)
- sehr gute Übereinstimmung der Topologie des resultierenden Baumes mit existierendem Wissen
- Baum beinhaltet bekannte evolutionär signifikante HIV/SIV Ereignisse
- genaue Topologie abhängig von Wahl von N  
identische Topologie für N=13-29 mit HIV/SIV Sequenz Compendium 2000 [3]

Ausschnitt: (mit N=15)



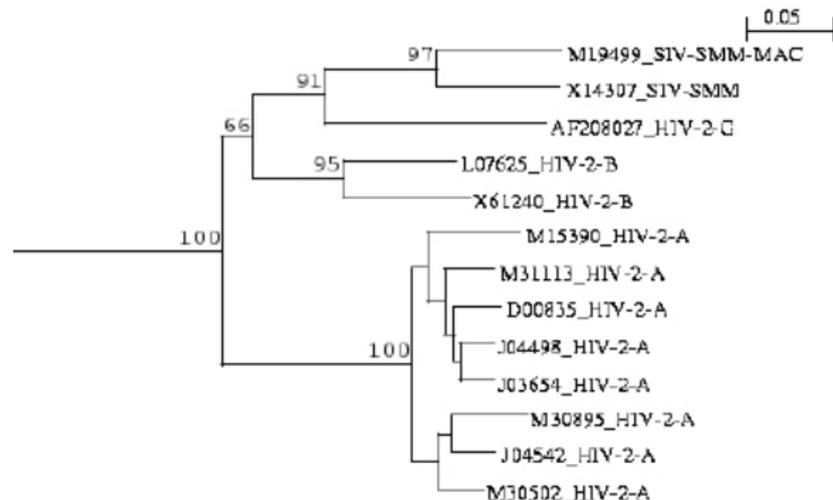
- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschießende Bemerkungen

- Gene *gag*, *pol* und *env* codieren Informationen über die strukturellen Proteine für neue Viruspartikel, *nef* codiert Protein für effiziente Vermehrung des Virus
- Gensequenzen wurden aus 66 HIV/SIV Genomen verwendet → Distanzmatrizen des N-lokales Dekodieren von *gag*, *pol* und *env* stimmt gut mit etablierten HIV/SIV Phylogeniebäumen für diese Regionen überein
- Einige Unterschiede bei *nef*, wobei diese möglicherweise darauf zurückzuführen sind, dass beim N-lokalen Dekodieren mehrdeutige Regionen berücksichtigt werden (im Gegensatz zu multiplen Alignments)
- Empirisch gute Werte für N in den Regionen: *gag* - N=11-23; *pol* - N=11-30; *env* - N=12-24 und *nef* - N=11-20

- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschießende Bemerkungen

- LTR ist RNA-Sequenz am Ende von jedem HIV/SIV Strang, dienen als Schalter zur Kontrolle neuer Viren
- Sequenzvergleich von 43 non-coding LTR-Regionen (enthalten viele Duplikationen/Insertionen/Deletionen)  
→ mehrdeutige Regionen bei multiplen Alignment
- keine Referenzbäume vorhanden  
→ Versuch der Erzeugung mit Hilfe von CLUSTAL-W, DIALIGN-2
- Abgleich der gewonnenen Bäume mit umfangreichen Wissen über HIV/SIV-Subtypen:  
CLUSTAL-W führte schlechte Trennung zwischen HIV-1, HIV-2 und SIV-Sequenzen durch, DIALIGN trennte Subtypen von HIV-1 nicht gut auf (z.B. HIV-1 N ist innerhalb von HIV-1 M)  
→ erwartungsgemäß schlechte Performance von Alignment-basierten Methoden

- Gute Trennung der HIV/SIV Subtypen durch N-lokales Dekodieren, bei  $N=10-21$
- Problem: fehlende Referenzbäume zur genauen Einschätzung des erstellten Baumes



- 1 Grundidee
- 2 Naiver Algorithmus
  - Definitionen
  - Lokales N-Dekodieren
  - Ermittlung der Distanzmatrix
  - Aussagefähigkeit der Distanzen
- 3 Verbesserungen
  - Verbesserung der Komplexität
  - Erweiterung des evolutionären Modells
- 4 Leistung bei HIV/SIV Subtyping
  - Kurze Sequenzen: HIV/SIV gag, pol, env und nef
  - Non-coding Long Terminal Repeats (LTR)
- 5 Abschließende Bemerkungen

- Erweiterung auf komplexeres evolutionäres Modell wäre sinnvoll
- Wahl von Parameter N entscheidend für sinnvolle Ergebnisse:  
N=13-20 sind gute empirische Standardwerte,  
→ weitere Untersuchungen notwendig
- Berücksichtigung auch von mehrdeutigen Regionen (z.B. LTR),  
aber: Problem der Validierung
- Implementation des verbesserten Algorithmus verfügbar [4]

# Literatur

-  Didier G, Debomy L, Pupin M, Laprevotte I, *Comparing sequences without using alignments: application to HIV/SIV subtyping*, BMC Bioinformatics. 2007 Jan 02
-  Didier G, Laprevotte I, Pupin M, Hénaut A, *Local decoding of sequences and alignment-free comparison*, J Comp Biol. 2006, 13: 1465-1476
-  *The 2000 HIV Sequence Compendium*, <http://www.hiv.lanl.gov/content/hiv-db/COMPENDIUM/2000/HIV12SIVcomplete.pdf>
-  *SCeNE - Prototypimplementierung des N-lokalen Dekodierens*, <http://iml.univ-mrs.fr/~didier/laprevot/>